

# **Klassifikation von Schwingungssignalen technischer Systeme mittels FUZZY-Methoden**

## **Dissertation**

zur Erlangung des Grades eines  
Doktor-Ingenieurs

vorgelegt von  
Dipl.-Ing. Jens Dobras  
aus Delmenhorst

genehmigt von der  
Fakultät für Bergbau, Hüttenwesen und Maschinenwesen  
der Technischen Universität Clausthal

Tag der mündlichen Prüfung:  
25. Juni 2004

Vorsitzender der Promotionskommission:

Prof. Dr. H.-J. Barth

Hauptberichterstatter:

Prof. Dr. D. Behr

Berichterstatter:

PD. Dr. J. Strackeljan

Meinen Eltern Alfred und Marga Dobras in Dankbarkeit gewidmet.





# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als Wissenschaftlicher Mitarbeiter am Institut für Technische Mechanik, Abteilung für Schwingungsmechanik und Maschinendiagnostik, der Technischen Universität Clausthal.

Allen, die zu ihrem Gelingen beigetragen haben, möchte ich an dieser Stelle herzlich danken.

Besonderer Dank gebührt meinem hochverehrten Lehrer, Herrn Universitätsprofessor Dr. rer. nat. Dietrich Behr für die Anregung zu dieser Arbeit. Weit über die alleinige Übernahme des Hauptreferates hinaus war Prof. Behr durch sein großes Interesse, seine stetige Diskussionsbereitschaft und seine Offenheit gegenüber neuen Ideen eine wesentliche Unterstützung bei der Erstellung dieser Dissertation.

Dank gebührt auch Herrn Privatdozent Dr.-Ing. Jens Strackeljan, der mir als Korreferent in ausführlichen Diskussionen wertvolle Hinweise geben konnte und mit seiner kritischen Durchsicht einen unverzichtbaren Beitrag zum Entstehen der Arbeit leistete.

Darüber hinaus danke ich Herrn Universitätsprofessor Dr. Behr und Herrn Privatdozent Dr. Strackeljan für die hervorragenden Rahmenbedingungen, die mir am Institut für Technische Mechanik geboten wurden, und für das sehr angenehme und herzliche Arbeitsklima.

Allen Mitarbeitern des Institutes für Technische Mechanik, besonders Frau Dr. Xue Feng und Herrn Dr. Lothar Schmidt, sei für ihre stetige Unterstützung und ihre kollegiale Zusammenarbeit gedankt. Weiterhin danke ich speziell Herrn Bernd Riechel und Herrn Dietrich Goldmann für die Anfertigung zahlreicher Prüfstände, ohne die viele experimentelle Untersuchungen nicht möglich gewesen wären.

Besonderen Dank schulde ich auch meiner Schwester Dipl.-Kffr. Susanne Gräf mit ihrer Familie und meinen Freunden, die mir in all der Zeit eine wesentliche Stütze waren.

Zum Schluß, aber damit um so herzlicher, möchte ich meinen Eltern Alfred und Marga Dobras danken. Ihre selbstlose und fürsorgliche Unterstützung und das beständige Interesse an meiner Arbeit haben mir sehr geholfen.



# Inhaltsverzeichnis

- Inhaltsverzeichnis .....I
- 1 Einleitung..... 1
  - 1.1 Zielsetzung der Arbeit ..... 3
  - 1.2 Stand der Forschung ..... 5
- 2 Grundlegende Betrachtungen..... 11
  - 2.1 Der objektive Bewertungsmaßstab ..... 11
  - 2.2 Mustererkennungssysteme ..... 13
    - 2.2.1 Sensor..... 14
    - 2.2.2 Signalvorverarbeitung ..... 15
    - 2.2.3 Merkmalserzeugung ..... 15
    - 2.2.4 Merkmalsauswahl..... 16
    - 2.2.5 Klassifikator ..... 17
    - 2.2.6 Wissensbasierte Interpretation..... 19
- 3 Fuzzy-Klassifikationskonzept..... 21
  - 3.1 Unscharfe Mengen und Zugehörigkeitsfunktionen ..... 22
  - 3.2 Zugehörigkeitsfunktion mit gewichtetem Distanzmaß ..... 25
    - 3.2.1 Distanzmaß auf Basis des MAHALANOBIS-Abstandes ..... 26
- 4 Klassifikatorbezogene Merkmalsauswahl ..... 33
  - 4.1 Gütekriterien der klassifikatorbezogenen Merkmalsauswahl..... 34
    - 4.1.1 Die Reklassierungsgüte..... 34
    - 4.1.2 Die mittlere Zugehörigkeitsdifferenz ..... 35
  - 4.2 Suchstrategien zur Merkmalsauswahl ..... 36
    - 4.2.1 Sequentielle Vorwärtssuche mit beschränkt optimaler Merkmalsauswahl..... 37

---

4.3	Merkmalskombinationen ohne elliptische Clusterstrukturen .....	39
5	Divisive hierarchische Clustering mittels Wasserscheiden Transformation (DHCL <sub>WST</sub> ).....	45
5.1	Segmentierung mittels Wasserscheiden-Transformation.....	50
5.1.1	Wasserscheiden-Transformation.....	52
5.2	Erzeugung WST-abhängiger Clusterstrukturen.....	57
6	Anwendungen.....	59
6.1	Subgingivale Konkrementerkennung zur Parodontitisvorsorge .....	59
6.1.1	Entstehung und Ursachen einer Parodontitis.....	60
6.1.2	Anzeichen einer marginalen Parodontitis.....	60
6.1.3	Erkrankungsformen.....	61
6.1.4	Phasen der systematischen Parodontaltherapie.....	62
6.1.5	Probleme bei der heutigen Parodontitisbehandlung .....	66
6.1.6	Grundprinzip der automatisierten Oberflächenerkennung .....	67
6.1.7	Ergebnisse der automatischen Konkrementerkennung.....	69
6.2	Akustische Güteprüfung von Mikrowellenbackröhren.....	75
6.2.1	Erzeugung von Mikrowellenstrahlung .....	75
6.2.2	Physiologische Wirkung und Grenzwerte hochfrequenter Mikrowellenstrahlung .....	77
6.2.3	Bisheriges Konzept der Qualitätsprüfung .....	78
6.2.4	Untersuchungsmethoden und Grundlagen der akustischen Güteprüfung.....	79
6.2.5	Klassifikationsergebnisse .....	82
6.3	Akustische Leckagedetektion in Erdgasanlagen .....	89
6.3.1	Aufbereitung von Erdgas.....	90
6.3.2	Überwachung von Erdgasanlagen.....	92
6.3.3	Laborversuchsanlage zur Leckagedetektion.....	93

---

6.3.4	Wissensakquisition mittels $\text{DHCL}_{\text{WST}}$ .....	95
7	Zusammenfassung.....	97
	Symbolverzeichnis.....	99
	Literaturverzeichnis .....	101



# 1 Einleitung

Das wirtschaftliche Handeln unterliegt wie nahezu jedes zielgerichtete menschliche Handeln dem allgemeinen Vernunftprinzip. Es fordert, ein gesetztes Ziel mit dem Einsatz möglichst geringer Mittel zu erreichen. Aus betriebswirtschaftlicher Sicht folgt daraus das sogenannte ökonomische Prinzip, welches fordert, mit einem gegebenen Aufwand an Produktionsfaktoren (menschliche Arbeitsleistung, Betriebsmittel, Werkstoffe) den größtmöglichen Güterertrag zu erzielen [Wöh81]. Die Aufgabe des Ingenieurs ist wiederum eindeutig aus diesem Prinzip abzuleiten. Ihm obliegt es, Maschinen und Anlagen wirtschaftlich zu bauen und zu betreiben. Dies bedeutet neben der Reduzierung des Entwicklungs- und Fertigungsaufwandes auch eine Gewährleistung des Betriebs der maschinellen Anlagen mit einem Maximum an Wirtschaftlichkeit, Qualität und Sicherheit.




Abbildung 1.1: Produktionsziele [Kle98]

Dabei hängt die Wirtschaftlichkeit moderner, kapitalintensiver Anlagen und Fertigungseinrichtungen aber nicht nur von ihrer Auslastung sondern insbesondere auch von der Qualität der produzierten Güter und der Anlagenverfügbarkeit ab. Störungen und unvorhergesehene Betriebsunterbrechungen können daher die Wirtschaftlichkeit der Produktion oder des gesamten Unternehmens gefährden und mit erheblichen Auswirkungen auf die Sicherheit von Mensch und Umwelt einhergehen. Überwachungs-

und Diagnosesysteme können in diesem Zusammenhang einen wesentlichen Beitrag leisten.

Eine Überwachung und Diagnose von Anlagen, Maschinen und Produktionsgütern muß immer dann erfolgen, wenn Zustände in Folge von Verschleiß oder Ermüdung Änderungen unterworfen sind. Da die zugrunde liegenden Schädigungsmechanismen dynamische Vorgänge voraussetzen, kommen zur Zustandsbeurteilung vor allem Schwingungs- und Körperschallsignale in Betracht. Durch die moderne rechnergestützte Meßtechnik bietet sich die Verwendung „intelligenter“ computergestützter Diagnosesysteme geradezu an, da die bereits auf dem Rechner digitalisierten Schwingungssignale direkt in Form von zeit- und wertdiskreten Zeitreihen einem Mustererkennungssystem zur Verarbeitung übergeben werden können.

Ein besonderes Problem der Verarbeitung von Schwingungs- und Körperschallsignalen stellen allerdings die erforderlichen hohen Abtastfrequenzen und die für eine ausreichende Frequenzauflösung notwendige Meßensterlänge dar. Sie zwingen den Anwender zu einer Reduktion des Merkmalsraumes mittels geeigneter Merkmalsauswahlverfahren. In der vorliegenden Arbeit werden zu diesem Zweck die vor allem in den letzten Jahren entwickelten klassifikatorgebundenen Methoden, die sogenannten „Wrapper-Ansätze“, verwendet.

Das zweite wichtige Kernstück eines Mustererkennungssystems ist der verwendete Klassifikator. Auf Basis eines vor einigen Jahren am Institut für Technische Mechanik der TU Clausthal entwickelten Fuzzy-Prototyp-Klassifikators mit gewichtetem Distanzmaß werden Methoden zur divisiven hierarischen Clusterung vorgestellt, die es dem Mustererkennungssystem erlauben die semantische Klassenstruktur an die speziellen Anforderungen des Klassifikators anzupassen. Zum Einsatz kommen dabei Methoden aus der digitalen Bildverarbeitung, die im Rahmen dieser Arbeit erstmals zur Klassifikation von Schwingungssignalen eingesetzt werden.

Formal läßt sich das vorgestellte Mustererkennungssystem somit in die Funktionsblöcke Signalerfassung, Merkmalerzeugung, Merkmalsauswahl und FUZZY-Klassifikator mit automatischer Clusterung unterteilen. All diese Stufen sind mittels der Softwareentwicklungsumgebung LabVIEW realisiert. Die Grundidee hinter LabVIEW stammt aus dem Bereich der Meßtechnik und verwendet das vertraute Denkmodell der graphischen Blockschaltbilder zur Codegenerierung. Neben der Möglichkeit, Prozesse und Algorithmen durch eine sehr intuitive Form mit Hilfe von Datenflußdiagrammen zu programmieren, bietet LabVIEW leistungsfähige Entwicklungstools für die rechnergesteuerte Datenerfassung und Datenpräsentation. Programm-Bibliotheken zur „intelligenten“ automatischen Mustererkennung und Datenanalyse mittels Fuzzy-



Methoden standen bisher allerdings nicht zur Verfügung. Diese Lücke zwischen der Datenerfassung und der Datenpräsentation wird nun erstmals durch die im Rahmen dieser Arbeit entstandene SubVI-Toolbox geschlossen. Darauf aufbauend werden Systeme zur Schwingungsanalyse entwickelt, die diese Toolbox und die darin implementierten unscharfen Methoden erfolgreich auf den Gebieten

- der automatischen Maschinenüberwachung zur Leckageortung an Gasleitungen,
- der akustischen Güteprüfung zur Erkennung von Einschnürungen in Blechformteilen und
- der zahnmedizinischen Diagnostik zur Detektion subgingivaler Konkreme

nutzen.

## 1.1 Zielsetzung der Arbeit

Softcomputingmethoden zur Mustererkennung und Datenanalyse lassen sich grundsätzlich in die drei Bereiche

- der wissensbasierten,
- der neuronalen und
- der algorithmischen

Methoden unterteilen [Zim93].

Im Bereich der wissensbasierten Methoden wird Wissen über Ursache-Wirkungs-Zusammenhänge erfaßt und in der Wissensbasis des sog. Expertensystems abgelegt [Buc83], [Boo89]. Liegt das zur Problemlösung benötigte Wissen allerdings nur sehr ungenau und unstrukturiert vor und läßt sich mit vertretbarem Aufwand kein (mathematisch) beschreibbarer Zusammenhang zwischen Objektzustand und Klassenzugehörigkeit herstellen, so können die wissensbasierten Methoden nicht eingesetzt werden. Gerade bei ingenieurwissenschaftlichen Fragestellungen der Klassifikation von Schwingungssignalen ist dies jedoch häufiger der Fall.

Diese Problemstellungen lassen sich jedoch sehr gut mit unscharfen (fuzzy) algorithmischen und neuronalen Methoden bearbeiten. Beide Methoden verzichten auf eine mathematische Modellierung des Problems und versuchen vielmehr das menschliche Entscheidungsverhalten nachzubilden. In diesem Kontext weisen die Künstlichen Neuronalen Netze (KNN) – neben ihren positiven Eigenschaften – jedoch gegenüber den Fuzzy-Klassifikatoren einige einschränkende Nachteile auf:

1. Die Netzarchitektur ist nicht aus der Aufgabenstellung ableitbar und nur durch Erfahrungswissen und empirische Tests zu ermitteln.

2. KNN zeigen ein sogenanntes „black box“-Verhalten, das eine Analyse des in den Gewichtungsfaktoren gespeicherten Wissens sehr schwierig macht.
3. Das Trainieren eines KNN stellt einen iterativen, rechenzeitaufwendigen Vorgang dar, der um viele Größenordnungen höher liegen kann als bei algorithmischen Fuzzy-Systemen [Hes98].

Seit etwa Anfang der neunziger Jahre wird deshalb versucht, die Nachteile durch eine Kombination beider Ansätze, die sogenannten Neuro-Fuzzy-Methoden [Bot98], zu kompensieren. Dennoch steht, gerade im Hinblick auf den zuletzt genannten Punkt, die Klassifikation von Schwingungssignalen mittels eines Fuzzy-Prototyp-Klassifikators im Zentrum dieser Arbeit.

Die Grundidee eines Fuzzy-Prototyp-Klassifikators besteht darin, zunächst jede Klasse durch einen klassenrepräsentativen bzw. prototypischen Vektor zu beschreiben. Der berechnete Prototyp wird dann neben weiteren Parametern dazu genutzt, um eine Funktion zu definieren, mit der Merkmalsvektoren unbekannter Objekte einer bekannten Klasse zugeordnet werden können. Dabei ist für die Berechnung der Prototypen und der Zugehörigkeitsfunktion die Auswahl geeigneter Merkmale aus einer größeren Merkmalsmenge von entscheidender Bedeutung. Neben vielen Ansätzen, die diese Dimensionsreduzierung der Merkmalsvektoren getrennt vom Klassifikator durchführen [Jol86], [Liu92], [Der97], wird in dieser Arbeit eine Methode diskutiert, die den Klassifikator direkt in die Suche nach signifikanten Merkmalen integriert. Dazu wird aus der vorgegebenen Lernmenge eine Merkmalskombination selektiert, für die ein damit erzeugter Klassifikator eine geringe empirische Fehlerrate aufweist. Diese sogenannten „Wrapper“-Ansätze findet man beispielsweise in [Str93], [Beh95] und [Ott98], wo sie gleichfalls zur Analyse von Schwingungssignalen verwendet werden.

In [Str93] wird nun ein Fuzzy-Prototyp-Klassifikator vorgeschlagen, der jede Klasse durch einen Prototypen (Schwerpunktsvektor) und die Eigenwerte und -vektoren einer Kovarianzmatrix beschreibt. Mustererkennungssysteme in Verbindung mit dieser Art von Klassifikator sind für schwingungstechnische Untersuchungen häufig gut geeignet, weisen jedoch zwei entscheidende Einschränkungen auf:

1. Jede semantische Klasse wird durch nur einen einzigen Prototypen mit zugehöriger Kovarianzmatrix beschrieben. Dies setzt implizit eine Normalverteilung der Stichprobenvektoren voraus, wodurch ausschließlich Clusterstrukturen in Form von Hyperellipsoiden erkannt werden können. Bildet eine Klasse mehrere getrennte Cluster im Merkmalsraum oder weicht die Clusterstruktur von der bevorzugten Form ab, liefert die Methode in aller Regel schlechte Resultate. Sie weist Merk-

malkombinationen, die zur Klassifikation gut geeignet wären, durch eine schlechte Gütebewertung während der Merkmalsauswahl zurück.

2. Aufgrund der Beschreibung der semantischen Klassen durch nur einen einzigen Prototypen müssen die Merkmalsvektoren der Lernmenge entsprechend ihrer scharfen Klassenzugehörigkeit diesem gleichgewichtet zugeordnet werden.

Im Rahmen dieser Arbeit werden nun Lösungswege aufgezeigt, um diese Nachteile zu beheben und gleichzeitig die Klassifikationsleistung des Mustererkennungssystems zu steigern. Bezogen auf die Klassifikation von Schwingungssignalen mittels Fuzzy-Methoden lassen sich somit folgende Ziele formulieren:

- Das in [Str93] vorgeschlagene klassifikatorbezogene Merkmalsauswahlverfahren soll so erweitert werden, daß jede semantische Klasse entsprechend ihrer natürlichen Clusterstruktur durch mehrere (Sub-)Klassen mit zugehörigen Prototypen und beigeordneten Kovarianzmatrizen zu beschreiben ist. Eine Bevorzugung bestimmter Clusterstrukturen ist zu vermeiden.
- Die Anzahl und Lage der klassenbeschreibenden Prototypen soll entsprechend der natürlichen Clusterstruktur jeder semantischen Klasse automatisch bestimmt werden, ohne dabei algorithmischen Einschränkungen zu unterliegen. Innerhalb der Algorithmen zur Prototypenbestimmung ist das Fuzzy-Konzept durch eine unscharfe (Sub-)Klassenzugehörigkeit der einzelnen Merkmalsvektoren zu erweitern.
- Alle Methoden und Algorithmen sollten völlig autonom ablaufen, d. h. a priori durch den Benutzer festzulegende ergebnisbeeinflussende Parametereingaben sind unbedingt zu vermeiden. Eventuell notwendige Parameterwerte sind aus der natürlichen Clusterstruktur abzuleiten.
- Die Erkennungsraten des erweiterten Mustererkennungssystems zur Klassifikation von Schwingungssignalen sollten über denen des ursprünglichen Systems und denen des eventuell vorher eingesetzten Prüfpersonals liegen.

## 1.2 Stand der Forschung

Auf Grund der großen Fülle an Veröffentlichungen zu den Themengebieten Maschinenüberwachung, Qualitätskontrolle und unscharfe Mustererkennung soll und kann an dieser Stelle nur ein kurzer Überblick vermittelt werden. Im folgenden Abschnitt wird daher auf einige beispielhafte Arbeiten verwiesen, die den Fortschritt und den aktuellen Stand der Entwicklungstätigkeiten angemessen wiedergeben.

Die Theorie unscharfer Mengen, die sogenannten Fuzzy Set Theorie, wurde 1965 von Lofti A. Zadeh [Zad65] eingeführt und kann als eine Verallgemeinerung der dualen Logik

und der klassischen Mengenlehre angesehen werden. Eine ausführliche Beschreibung findet man in [Zim93].

Einen wahren Applikationsboom – besonders in den asiatischen Ländern und den USA – erlebte die Fuzzy Set Theorie in verschiedenen Industriezweigen jedoch erst in den frühen neunziger Jahren. Die seitdem realisierten Systeme werden dabei häufig zur Lösung steuerungs- und regelungstechnischer Aufgabenstellungen mit Hilfe der sogenannten „fuzzy control“ eingesetzt. Zahlreiche Beiträge beschreiben diese Anwendungen und weisen auf die Vorteile von Fuzzy Konzepten gegenüber klassisch scharfen Steuerung- und Regelungstechnikansätzen hin, z. B. [Dri96], [Pal97] [Bac99], [Kra00] und [Kuh00]. Da es im Rahmen dieser Arbeit jedoch hauptsächlich um den Einsatz der Fuzzy-Set-Theorie in der Datenanalyse und Mustererkennung (fuzzy classification) geht, werden die Entwicklungen der Fuzzy-Technologien in der MSR-Technik im folgenden nicht weiter dargestellt.

Trotz erster technischer Anwendungen für Mustererkennungssysteme in den siebziger Jahren, erfolgte der Einsatz von Fuzzy-Technologien zur Datenanalyse und Mustererkennung erst in den mittleren bis späten achtziger Jahren. Im Gegensatz zu den klassischen Ingenieurwissenschaften, ist das Gebiet der unscharfen Mustererkennung also ein sehr junger Wissenschaftszweig, dessen Entwicklung stark durch den Fortschritt im Bau leistungsfähiger Kleinrechnersysteme begünstigt wurde.

Grundsätzlich lassen sich technische Anwendungen in drei Kategorien von Einsatzfällen entsprechend der Art des zu erkennenden Musters gliedern [Bun95]:

1. Anwendungen zur Überwachung von Prozeßzuständen,
2. Anwendungen zur Defekterkennung an Anlagen oder deren Teilen und
3. Anwendungen zur Überprüfung von Qualitätsparametern an Produkten.

Hinsichtlich der Klassifikationssicherheit und der Klassifizierungsgeschwindigkeit stellen alle drei Kategorien sehr unterschiedliche Anforderungen an das (unscharfe) Erkennungssystem. Während Anwendungen zur Qualitätsprüfung auf eine der Produktions- taktfrequenz angepaßte Klassifizierungsgeschwindigkeit angewiesen sind, spielt gerade bei den Anwendungen zur Prozeßüberwachung und zur Defekterkennung die Klassifizierungssicherheit eine dominierende Rolle.

Zur Kategorie der Überwachung von Prozeßzuständen zählen Anwendungen aus dem Bereich der Metallurgie [Pet91], der Chemie [Hes98], [Kuh00], [Sch01] und der Biochemie [Bac99]. In [Pet91] werden Kaltwalzprozesse und –anlagen überwacht. Konkret werden Zeitreihenausschnitte von bis zu 300 Meßwerten innerhalb der Merkmalserzeugung durch Koeffizienten von Gleichungssystemen approximiert,

wodurch sich eine Reduktion des Merkmalsvektors ergibt. Für den Einsatz zur Prozeßüberwachung werden ein Abstandsklassifikator und ein adaptiv arbeitendes Neuronales Netz vorgeschlagen. Es werden mehrere Abwandlungen der genannten Klassifikatoren sowie verschiedene Transformationen zur Reduktion des hochdimensionalen Merkmalsvektors getestet und unter Verwendung von simulierten Daten Erkennungsraten von bis zu 90 % erzielt.

In [Hes98] werden Konzepte zur Identifizierung gefährlicher Betriebszustände mit Hilfe Neuronaler Netze, Fuzzy Logik und tensororientierter Klassifikation entwickelt und in einer Laborreaktoranlage beispielhaft bei einer exothermen Referenzreaktion getestet. Durch den Einsatz der Mustererkennungsverfahren wird die sehr schwierige und z. T. sogar unmögliche analytische Modellierung komplexer, nichtlinearer chemischer Prozesse grundsätzlich umgangen. Das System wird mit Hilfe von Signalmustern der bestimmungsgemäßen und nichtbestimmungsgemäßen Betriebszustände in einer überwachten Prozedur trainiert. Auf diese Weise wird der nichtlineare Zusammenhang zwischen Prozeßparametern und Entscheidungsergebnis in den freien Parametern des jeweiligen Verfahrens (z. B. Verbindungsstärken bei neuronalen Netzen) abgebildet. Mit den Neuronalen Netzen werden dabei gegenüber den Fuzzy-Methoden um etwa 15 % bessere Reklassierungsraten von bis zu 100 % erreicht, dagegen benötigt z. B. das verwendete Perceptron-Netz um ca. 600 % längere Trainingszeiten. Das tensororientierte System fällt sowohl in der Reklassierungsrate, als auch in den Trainingszeiten weit hinter die beiden anderen Verfahren zurück.

In das Gebiet der Fehlererkennung können die Arbeiten [Beh89], [Str93], [Bun95], [Oes98] und [Str02] eingeordnet werden. [Beh89], [Str93] und [Str02] beschreiben den Einsatz von Fuzzy Methoden zur Erkennung von Wälzlagerschäden. Identifiziert werden mehrere Schädigungsarten, der Lagerstillstand und der Normalbetrieb mittels skalarer Zugehörigkeitsfunktionen, die sich an Funktionen aus der statistischen Beschreibung von Meßwertschwankungen orientieren. Die Bestimmung der freien Parameter der Zugehörigkeitsfunktionen erfolgt anhand von Frequenzspektren und statistischer Kennwerte der Zeitdaten. Auch werden Methoden zur Merkmalsauswahl vorgestellt, die es erlauben aus hochdimensionalen Suchräumen suboptimale Merkmalskombinationen zu bestimmen.

Zusätzlich zur Fehlererkennung werden in [Str02] Methoden des Softcomputing (Künstliche Neuronale Netze, Evolutionäre Strategien und Fuzzy Logik) im Rahmen der Konstruktion und Optimierung von Laborzentrifugen eingesetzt. Dabei steht die Forderung nach einer hohen Laufstabilität der Zentrifugen im Mittelpunkt der Untersuchungen. Neben einer Mehrzieloptimierung mit dem Konzept der Pareto-Optimalität in Verbindung mit Evolutionären Suchstrategien, wird vor allem an

reduzierten Simulationsmodellen durch die Kopplung von Merkmalsauswahlverfahren mit Simulationsprogrammen nach relevanten Systemparametern für die sichere Auslegung von Laborzentrifugen gesucht.

In [Bun95] wird ein unscharfes Mustererkennungssystem zur on-line Rißerkennung von Drahtwalzringen beschrieben. Der dort verwendete unscharfe Abstandsklassifikator wird durch ein Verfahren zur Variation der Klasseneinteilung erweitert, was wiederum zu einer Verbesserung der Fehlererkennungsrate führt. Durch die eingeführten Methoden ist es möglich, eine automatische Erkennung von Längsrissen in Walzringen mit einer Erkennungsrate von über 90 % im Betriebszustand zu verwirklichen.

Werden in [Beh89], [Str93], [Bun95] und [Str02] das Eigengeräusch der beobachteten Maschinen bzw. Maschinenteile zur Defekterkennung herangezogen, werden in [Oes98] durch das Aussenden kurzer Stoßimpulse mittels eines Piezoaktors auch hochfrequente Eigenschwingungen des zu untersuchenden Bauteiles angeregt und zur Diagnose von Rissen herangezogen. Dabei wird für einen Großteil der zur Verfügung stehenden Linien des berechneten Amplitudenspektrums eine eigene Zugehörigkeitsfunktion erstellt. Zur Bildung des Referenzzustandes werden die Messungen der Lernphase nochmals in die Zugehörigkeitsfunktion eingesetzt und so die Zugehörigkeiten der Lernmenge zu sich selber – der Klasse „ungeschädigt“ – gebildet. Nachdem die Referenzklasse gebildet ist, können dann im weiter fortschreitenden Betrieb die Zugehörigkeiten der auflaufenden Frequenzspektren durch Einsetzen in die Zugehörigkeitsfunktionen berechnet werden. Während der durchgeführten Versuche konnte der Rißzeitpunkt durch das Abfallen der Zugehörigkeiten genau bestimmt werden.

Zur Kategorie der Qualitätskontrolle zählen Anwendungsbeispiele wie die Prüfung von Pkw-Getrieben [Jon97], Keramikkörpern [Jon98] oder auch die Überprüfung der Holzmaserungen von Furnierholz [Sto00]. In [Jon97] wird die Qualitätskontrolle von Pkw-Getrieben auf speziellen Getriebeprüfständen beschrieben. Anhand einer Klassifikation von Seitenbändern in hochauflösenden FFT-Spektren und drehwinkelsynchronen Ordnungsspektren mittels Künstlicher Neuronaler Netze werden Montage- und Bauteilfehler erkannt. Bei der Klangprüfung gebrannter Flächendachziegel in [Jon98] werden ebenfalls Künstliche Neuronale Netze eingesetzt, um Haarrisse, die insbesondere beim Abkühlen nach dem Brennprozeß auftreten können, zu erkennen. Für die Klangprüfung werden die Dachziegel angeschlagen und der abgestrahlte Luftschall mittels Mikrophon registriert. Das Spannungssignal des Mikrophons wird dann mittels FFT in den Frequenzbereich transformiert und dem Mustererkennungssystem als Merkmalsvektor übergeben. Zusätzlich zur akustischen Kontrolle werden die Dachziegel einer optischen Oberflächenkontrolle unterworfen. Neben der Überprüfung auf

Maßhaltigkeit können Löcher, Blasen, Ausbrüche und Risse ab 0,8 mm Breite erkannt werden. Das realisierte System kann bis zu 120 Dachziegel pro Minute überprüfen.

Die Qualitätskontrolle von Furnierholz anhand von Artefakten (Risse, Astlöcher, ...) im Holz bildet ein weiteres Beispiel für den Einsatz von Mustererkennungssystemen. In [Sto00] wird ein System zur Fehlerdetektierung und -klassifizierung mittels elektronischer Bilderarbeitung entworfen. Eine Zeilenkamera erstellt Bilder der Holzoberfläche, aus denen im Anschluß an die Bildvorverarbeitung 101 Merkmale durch Kantendetektoren, Gradientenextraktoren, etc. und mittels statistischer Methoden höherer Ordnung gewonnen werden. Zur Reduzierung der Merkmalsvektoren kommen genetische Algorithmen zum Einsatz. Die Klassifizierung erfolgt durch einen Fuzzy-C-Means-, einen Gustafsson-Kessel-Algorithmus oder mittels Neuronaler Netze.

Über diese drei technischen Anwendungskategorien hinaus werden Mustererkennungssysteme auch in vielen nichttechnischen Bereichen mit Erfolg eingesetzt. So werden z. B. seit den neunziger Jahren immer mehr Softcomputing-Methoden auch zur Lösung betriebswirtschaftlicher Problemstellungen eingesetzt. In [Rau97] wird ein System zur Erkennung von Kreditkartenbetrug vorgestellt. Durch die Berechnung weniger Merkmale aus den Zahlungsverkehrsdaten werden mittels einer Diskriminanzanalyse im 2-D-Merkmalsraum Zugehörigkeitsfunktionen ermittelt. In einer anschließenden Aggregation werden die Einzelaussagen durch Verknüpfung, Gewichtung und Kompensation zu einem Gesamturteil verdichtet. Die erreichten Erkennungsraten für einen Kreditkartenbetrug liegen bei ca. 85 %.

In der Kriminalistik und zur Kontrolle von Zugangs- oder Benutzungsberechtigungen werden Charakteristika von Personen, wie Gesichtszüge, Sprache [Tra99] und/oder Fingerabdrücke [Le01] rechnergestützt ausgewertet. In [Le01] werden Fingerabdrücke durch eine Kombination aus Fuzzy-Logik und evolutionärer Programmierung erkannt. Ein ganzer Fingerabdruck enthält normalerweise 50 bis 80 charakteristische Merkmale. In Übereinstimmung mit den Erkenntnissen des Federal Bureau of Investigation [FBI84] verwendet der Autor bis zu 12 Merkmale eines Teilabdruckes zur Personenbestimmung. Damit erreicht er eine Erkennungsrate von mindestens 96 % bei einer Laufzeit des Algorithmus von maximal 18 Sekunden.

In der Biologie werden Methoden der Mustererkennung z. B. zur automatischen Ruferkennung landwirtschaftlicher Nutztiere [Jah02] eingesetzt, um eine effiziente und artgerechte Überwachung zur Erhaltung und Verbesserung der Gesundheit zu erreichen. Da die Anatomie und die physiologischen Vorgänge der Lauterzeugung bei Wirbeltieren sehr ähnlich sind, wird bei der Entwicklung der automatischen Ruferkennung für landwirtschaftliche Nutztiere auf die Erfahrungen und Methoden der menschlichen

Spracherkennung zurückgegriffen. Die mittels STFFT berechneten Energiedichtespektren dienen als Merkmalsvektoren und werden durch den Einsatz von Hidden Markov Modellen [Tra99] und einer Parametrisierung der Lautäußerungen mit Mel-Cepstral-Koeffizienten weiterverarbeitet. Die erreichbaren Erkennungsraten für sieben unterschiedliche Rufe liegen zwischen 74 und 100 %. Das System wurde mit insgesamt 478 Rufen trainiert und mit weiteren 210 Rufen validiert.

Um einen Beitrag zur stärkeren Verbreitung von Mustererkennungssystemen auf Basis von Fuzzy-Klassifikatoren, die häufig eine Interpretation ihrer Parameter zulassen, gegenüber den Neuronalen Netzen zu erreichen, werden in der vorliegenden Arbeit folgende Problemschwerpunkte bearbeitet:

1. Wie viele und welche Merkmale trennen die vorgegebenen Klassen unter Berücksichtigung des gewählten Klassifikators im aufgespannten Merkmalsraum optimal oder zumindest suboptimal?
2. Wie sieht die optimale Klasseneinteilung und -struktur bezüglich eines gewählten Klassifikators und unter Berücksichtigung der Aufgabenstellung aus?

In [Str93], [Bun95], [Ott98], [Sch01], [Str02] werden Ansätze bezüglich der erstgenannten Problemstellung vorgestellt. Diese Arbeiten geben einen guten Überblick über

- klassifikatorunabhängige sowie -abhängige Verfahren,
- Gütemaße und
- Suchstrategien

im Zusammenhang mit der Merkmalsauswahl. In [Sch01] und [Str02] werden zudem Kombinationen aus Neuronalen Netzen und Evolutionären Algorithmen zur Suche optimaler Lösungen diskutiert.

Im Vergleich zur ersten Fragestellung wird die Problematik einer Variation der Klasseneinteilung nur relativ selten bearbeitet [Hän94] [Bun95], [Ott98]. In [Bun95] werden durch eine agglomerative hierarchische Clusterung Variationen der Klasseneinteilung erzeugt. Durch die Anpassung der Struktur einer semantischen Klasse an die vorliegende natürlichen Clusterstruktur werden die Erkennungsraten von Rissen in Drahtwalzringen von 75 % auf über 90 % gesteigert.

In [Ott98] wird ein Fuzzy-Prototyp-Klassifikator gezielt für die Anwendung in einem klassifikatorgebundenen Auswahlprozeß optimiert. Dazu entwickelt der Autor ein neues unscharfes Vektorquantisierungsverfahren, das den Vorteil bietet, daß die berechneten Prototypen unscharfe Klassenzugehörigkeiten besitzen können und die Repräsentanz im Sinne eines Qualitätsmaßes erfaßbar ist.



## 2 Grundlegende Betrachtungen

Heute werden zur Maschinenüberwachung überwiegend Experten oder rechnergestützte regelbasierte Systeme eingesetzt. Mittels Toleranzschemata werden Systemzustände und Qualitäten beschrieben. Jeder Zustand, der erkannt werden soll, muß von seinen physikalischen Grundlagen verstanden, und des weiteren algorithmisch klar zu beschreiben sein. Sehr detaillierte Kenntnisse des Fertigungsprozesses und Erfahrung in der Programmierung sind dazu Voraussetzung. Dies sind harte und kostenintensive Anforderungen. Der Einsatz von automatisierten Diagnosesystemen auf Basis von trainierbaren Mustererkennungsverfahren erscheint daher als erheblich komfortabler und wirtschaftlicher.

Die Messung von Schwingungssignalen ist für viele Anwendungsfälle eine geeignete Grundlage zur Charakterisierung des Zustandes eines technischen Objektes und eröffnet damit weitreichende Möglichkeiten einer qualitativen und quantitativen Zustandserkennung. Aus diesem Grund wird sich diese Arbeit vorrangig mit dem Entwurf und der Optimierung eines Mustererkennungssystems speziell für die Problemstellung der Klassifikation von Schwingungssignalen befassen. Da sich ein modellhafter und somit mathematisch beschreibbarer Zusammenhang zwischen dem Objektzustand und den Schwingungssignalen nur in seltenen Fällen angeben läßt, sind in diesen Fällen solche Klassifikationsverfahren besonders geeignet, deren Wissenserwerb auf Grund gelernter Beispiele mit möglichst eindeutig vorklassifizierten Repräsentanten verschiedener Zustandsformen erfolgt.

### 2.1 Der objektive Bewertungsmaßstab

Oberstes Ziel der Produktion ist es, nur einwandfreie Produkte an den Kunden abzugeben. Um dies zu gewährleisten, werden seit vielen Jahren Prüfverfahren zur Maschinenüberwachung und Qualitätskontrolle in der Industrie eingesetzt. In der Ziegelindustrie erfolgt z. B. häufig eine Endprüfung mit angelerntem Personal, das jeden Ziegel mit einem Holzstock anschlägt und dann hört, ob er „in Ordnung“ ist oder Ausschuß darstellt. Diese traditionelle Methode mit dem Einsatz von Prüfpersonal ist häufig gekennzeichnet durch:

- Subjektivität der Entscheidung:  
Die Beurteilung der Qualität durch den Prüfer ist u. a. abhängig von seiner „Tagesform“, seines aktuellen Ermüdungsgrades, seiner persönlichen Ausschußquote, die er subjektiv erwartet, etc.

- Ungenügende Reproduzierbarkeit der Entscheidung:  
Wiederholungsprüfungen bereits geprüfter Produkte durch dasselbe Prüfpersonal ergeben unterschiedliche qualitative Einstufungen gegenüber der Erstprüfung. Es fehlt die eindeutige Reproduzierbarkeit. Ebenfalls ist die Geschlossenheit der Entscheidungen zwischen verschiedenen Testern erfahrungsgemäß nicht einwandfrei.

Der Prüfer übernimmt also die alleinige Verantwortung für seine Qualitätsbeurteilung. Objektive Meßhilfsmittel und Meßmethoden stehen nicht zur Verfügung, woraus besondere Probleme resultieren:

- Menschliche Tester lernen ihre Kunst von einem erfahrenen Tester im wesentlichen durch Zuhören und Zuschauen. Ein ausgebildeter Tester kann seine Prüfkriterien oft nur sehr vage beschreiben. Die Ausbildung und die Verfügbarkeit einer ausreichenden Menge von Testern ist somit nur unzureichend zu gewährleisten.
- Der Mensch verfügt in der Regel nicht über die Fähigkeit, eine Absolutbewertung durchzuführen. Seine Bewertung ist immer abhängig von einer Referenz der beurteilten Stichproben. Die sehr wichtige Aufgabe der fortlaufenden Beobachtung der Stabilität des Fertigungsprozesses kann nicht wahrgenommen werden.
- Subjektiv festgestellte Qualitätsmerkmale können im Qualitätssicherungsverfahren sehr schnell zu Problemen und Unstimmigkeiten führen. Die Beurteilung des Kunden kann sich von der des Herstellers unterscheiden. Eine unstrittige Spezifikation im Sinne eines Qualitätsmaßes für die Produkteigenschaften ist unmöglich.

All diese Punkte bewegen Unternehmensleitungen häufig zur Einführung einer automatisierten Überwachungs- und Prüfanlage, um unmittelbar Kosten zu sparen, eine zuverlässige und reproduzierbare Prüfung durchzuführen und den Ausschuß auf tatsächlich defekte Produkte zu begrenzen.

Unabhängig von der Vorgehensweise bei der automatischen Überwachung besteht grundsätzlich die Forderung, Prüfungen zu objektivieren. Die Einführung eines zweckmäßigen Bewertungsmaßstabes ist somit unabdingbare Voraussetzung. Ihre Festlegung wird in der Regel von den zuvor auch für die Tester geltenden Aussagemöglichkeiten bestimmt:

- Gut-Schlecht-Beurteilung:  
Möglich sind reine 2 Klassensysteme: sogenannte Gut-Schlecht-Systeme. Die Bewertungsprozedur entspricht damit der Zuordnung eines Musters zu einer der beiden möglichen Beurteilungsklassen (i. f. kurz Klassen genannt).

- Benotungssysteme:  
Häufig findet man auch die Einordnung eines Musters in ein Benotungssystem mit einer festgelegten Anzahl von Noten. Die i. O.-Grenze wird hier durch eine festgesetzte Notengrenze bestimmt.
- Fehlerklassifikation:  
Falls die Tester in der Lage sind, Fehlertypen zu unterscheiden, sollte der Bewertungsmaßstab dies berücksichtigen.

Allen Systemen ist gemeinsam, daß jedes Muster als ein Ganzes betrachtet, bewertet und unabhängig von anderen Mustern genau einer der vorgesehenen Beurteilungsklassen zugeordnet wird. Dieser Prozeß wird in der Mustererkennung als Klassifikation bezeichnet. Um diesen Beurteilungsprozeß zu automatisieren, finden die Verfahren zur Mustererkennung und Klassifikation in Verbindung mit leistungsfähigen Algorithmen der Signalverarbeitung Anwendung.

## 2.2 Mustererkennungssysteme

Eine allgemein gültige Definition für den Begriff der Mustererkennung zu finden, ist keinesfalls trivial. Befragt man eine handvoll Experten, wird man ebenso viele unterschiedliche Definitionen bekommen. Eine nach Meinung des Autors zufriedenstellende Definition ist die nach BEZDEK und PAL:

“Pattern recognition is the search for structure in data.”

=

“Mustererkennung ist die Suche nach Strukturen in Daten.“

Kurz um, Mustererkennungssysteme sind Anwendungen, die mit Methoden der Datenanalyse sinnvolle Informationen gewinnen. Dabei werden physikalische Objekte und Vorgänge, sogenannte Muster, erfaßt und einer Menge von Objekten und Ereignissen mit ähnlichen Eigenschaften zugeordnet. Eine derartige Zuordnung zu einer zuvor definierten Objektmenge, die als Klasse bezeichnet wird, kennzeichnet einen Klassifikationsprozeß. Dabei kommt der Frage, welche Kriterien bzw. charakteristischen Merkmale verwendet werden können, um die bei technischen Klassifikationsaufgaben in der Regel als physikalische Größen vorliegenden unbekannten Muster einer bekannten Klasse zuzuweisen, eine wesentliche Bedeutung zu. Sehr häufig steht eine Vielzahl von Merkmalen zur Verfügung, die prinzipiell als Kriterien für eine Klassifikation herangezogen werden können. Da aber nicht alle Merkmale in gleicher Weise geeignet sein werden, die Klassifikation durchzuführen, stellt sich als ein weiteres Problem der Mustererkennung das der Merkmalsauswahl [Str93].

Diese Definition läßt erahnen, daß in praktisch allen Bereichen von Wissenschaft und Technik die Mustererkennung bzw. Datenanalyse eine mehr oder weniger bedeutende Rolle spielt. Auch wenn es gerade im Hinblick auf die in Abschnitt 5 vorgestellten sehr unterschiedlichen Anwendungsfälle unverständlich oder unglaublich erscheint, ist die Aufgabe der Mustererkennung oft sehr ähnlich. Zwar gibt es wichtige, einzelfallabhängige Aspekte bei der Durchführung der unterschiedlichen Meßaufgaben – hauptsächlich begründet durch die Bereiche Expertenwissen und Sensorik, den erforderlichen Analyseverfahren und Klassifikationssystemen liegt jedoch in jedem Fall ein grundsätzlich einheitliches Modell eines Mustererkennungssystems zugrunde (Abbildung 2.1):

1. Signalaufnehmer oder -wandler (Meßfühler),
2. Singnalvorverarbeitung,
3. Merkmalerzeugung,
4. Merkmalsauswahl,
5. Klassifikation
6. wissensbasierte Interpretation.




Abbildung 2.1: Modell eines Mustererkennungssystems mit Klassifikator bezogener Merkmalsauswahl

### 2.2.1 Sensor

Mit Hilfe eines Sensors werden die Objekte der physikalischen Welt abstrahiert und in analoge Meßdaten überführt. Man macht sie so einer Weiterverarbeitung zugänglich. Bei diesem ersten Verarbeitungsschritt erhält man eine Reihe von Meßdatenvektoren, die sog. Stichprobenvektoren, die häufig numerischer Natur sind. Die Dimension der Stichprobenvektoren kann niederdimensional, mit nur einigen wenigen Meßgrößen, aber

auch hochdimensional, mit z. B. mehreren tausend Zeitdaten, sein. Jeder Stichprobenvektor ist ein Element des Signaldatenraumes mindestens gleicher Dimension.

Der Auswahl der Sensorik ist dabei eine sehr hohe Bedeutung beizumessen, da es in der Regel eine anspruchsvolle Aufgabe darstellt, die für eine möglichst umfassende Überwachungsaufgabe optimale Konstellation von Sensortyp, Sensoranzahl und dem zu detektierenden Schaden zu finden. Die anschließende Merkmalsauswahl und Klassifikation kann insbesondere erst dann zielführende Ergebnisse liefern, wenn im gemessenen Signal auch prägnante Signalmerkmale enthalten sind, die eine Unterscheidung von Systemzuständen überhaupt gestatten. Fehler im Bereich der Signalerfassung können also auch durch eine besonders leistungsfähige Klassifikationsstufe nicht mehr eliminiert werden. Die Auswahl der Sensoren erfordert sowohl das Know-how des System-Betreibers als auch dasjenige des Meßtechnikerns. Dabei sollten folgende Anforderungen Berücksichtigung finden:

- Qualifikation und Häufigkeit der Schäden und ihre Bedeutung für die Klassifikation,
- Zugänglichkeit (z.B. berührungslose Messung) und
- Montageort.

Eine anschließende technisch-wirtschaftliche Bewertung des Anforderungsprofils führt dann unter Beachtung der gegenseitigen Interdependenzen zur Favorisierung eines Sensorkonzeptes.

### **2.2.2 Signalvorverarbeitung**

Jeder technisch unterstützter Bewertungsprozeß erfordert eine elektronische Signalvorverarbeitung. Sie umfaßt alle notwendigen Aufgaben, die standardmäßig für

- die Konditionierung des Sensorsignals,
- die Abtastung und
- die A/D-Umsetzung

anfallen. Besondere Bedeutung kommt dabei der zeitlichen Segmentierung des Sensorsignals zu, an die sich weitere signalmanipulierende Verfahren, wie z. B. Filter- und Fensteroperationen, als Grundvoraussetzung einer A/D-Umsetzung bzw. zur Unterstützung späterer Analysefunktionen anschließen.

### **2.2.3 Merkmalerzeugung**

Nach erfolgter Digitalisierung und Signalvorverarbeitung der analogen Meßgrößen bzw. Stichprobenvektoren werden mittels digitaler und komplexer Signalverarbeitungsalgorithmen signifikante Signalmerkmale bestimmt. Dieses Vorgehen ist notwendig, weil das

Beurteilungskriterium in den meisten Fällen nicht unmittelbar aus dem Signalverlauf ablesbar ist. Dabei ist leicht einsichtig, daß unterschiedliche Aufgabenstellungen in der Regel auch unterschiedliche Merkmale und davon abgeleitete unterschiedliche Analysefunktionen benötigen. Zur Merkmalerzeugung werden daher Verfahren der digitalen Signalverarbeitung aus dem Zeitbereich, wie beispielsweise

- Auto- und Kreuzkorrelation,
- Leistung und
- Spitzenwerte,

dem Frequenzbereich, wie z. B.

- Fast-Fourier-Transformation,
- Wigner-Verteilung,
- Wavelets und
- Ordnungsanalyse

und statische Parameter, wie

- Varianz und
- Mittelwerte höherer Ordnung

angewendet. Das Ergebnis dieser digitalen Signalverarbeitung ergänzt um eventuelle Betriebsdaten (Drehzahlen, Betriebsdrücke, Volumenströme, etc.), sofern diese aufgabenspezifisch benötigt werden, bilden den sog. Merkmalsvektor. Er bestimmt wiederum die Dimension des Merkmalsraumes.

Besonders für erste Untersuchungen im Labormaßstab sind leistungsfähige und umfassende Tool-Bibliotheken zur Merkmalerzeugung notwendig. Dies war unter anderem mit ein Grund für die Wahl von LabVIEW als Entwicklungsumgebung für das im Rahmen dieser Arbeit beschriebene Mustererkennungssystem.

#### 2.2.4 Merkmalsauswahl

Der Abstand  $\Delta f$  von Frequenzlinien der Diskreten-Fourier-Transformation (DFT) ist umgekehrt proportional der Meßfensterbreite  $T_F$  bzw. umgekehrt proportional dem Produkt aus Meßwerteanzahl  $N$  und Abtastintervall  $\Delta t$ :

$$\Delta f = \frac{1}{T_F} = \frac{1}{N \cdot \Delta t} \quad (2.1)$$

Daraus ergibt sich das häufige Problem – vor allem bei der Verarbeitung von Schwingungs- und Körperschallsignalen –, daß die im oberen Kilohertzbereich liegenden

Abtastfrequenzen in Verbindung mit einer hohen Auflösung im Frequenzbereich zu entsprechend langen Signaldaten- und Merkmalsvektoren führen. Dadurch wird der Anwender gezwungen den Merkmalsraum mittels geeigneter Merkmalsauswahlverfahren zu reduzieren.

Die Merkmalsauswahl verfolgt dabei das Ziel, die signifikanten Merkmale (Informationen) im Signal in bezug auf die nachfolgend im Klassifikator durchzuführende Unterscheidung verschiedener Systemzustände vorzubereiten. Die Signifikanz der Merkmale zeigt sich, wenn der anschließende Klassifikator mit diesen Informationen verschiedene Systemzustände bzw. Qualitäten sicher unterscheiden kann.

Welche Merkmale eine zuverlässige Unterscheidung der vorgegebenen Systemzustände bzw. Qualitäten gestatteten, ist gewöhnlich nicht einfach zu ermitteln. Zu diesem Zweck werden oft lange Versuchsreihen durchgeführt, um aus der Vielzahl von Signalverarbeitungsverfahren einige erfolgversprechende auszuwählen. Meßtechniker und Prüfer arbeiten empirisch, wobei ihre Erfahrung oft das wichtigste Hilfsmittel darstellt, um die signifikanten Merkmale in den oft hochdimensionalen Merkmalsvektoren zu finden. In der vorliegenden Arbeit werden zum Zwecke der Merkmalsauswahl die vor allem in den letzten Jahren entwickelten sogenannten „Wrapper-Ansätze“ verwendet. Bei ihnen findet schon für die Gütebewertung (Abschnitt 4) innerhalb der Merkmalsauswahl der im nächsten Schritt zum Einsatz kommende spezielle Klassifikator Verwendung.

Am Ausgang dieses Verarbeitungsmoduls ergibt sich mittels des gewählten Auswahlverfahrens ein reduzierter Merkmalsvektor. In praxi zeigt sich, daß die Zuverlässigkeit eines Klassifikationssystems nicht zwangsläufig mit der Dimension des Merkmalsvektors steigt.

### **2.2.5 Klassifikator**

Der Klassifikator hat die Aufgabe, die Zuordnung eines Objektes zu zuvor definierten Objektklassen anhand des ihm übergebenen Merkmalsvektors durchzuführen. Die Anzahl der unterschiedlichen Objektklassen bestimmt die Dimension des Entscheidungsraumes. Um nun eine Klassifikationsaufgabe lösen zu können, muß vorausgesetzt werden, daß aus dem gemessenen Signal mittels der Merkmalerzeugung und -auswahl ein Merkmalsvektor mit signifikanten Merkmalen ermittelt wurde. Gelingt die Klassifikation, enthält das gemessene Signal diejenigen Informationen, die zur Unterscheidung verschiedener Systemzustände oder Qualitätsgrade nötig sind.

Im Rahmen dieser Arbeit basiert der Klassifikator auf einem Verfahren der unscharfen, algorithmischen Mustererkennung. Hervorzuheben sind in diesem Zusammenhang die

Trainierbarkeitseigenschaften des Klassifikators. Er muß nicht anwendungsspezifisch programmiert werden, sondern wird anhand von Mustern trainiert.

Unter den verschiedenen Trainingsstrategien hat das sogenannte überwachte Lernen besondere Bedeutung erlangt. Innerhalb des Trainingsprozesses wird dem Klassifikator ein Satz an Merkmalsvektoren (Lernmenge) vorgegeben, den ein Experte a-priori einer bestimmten Objektklasse zugeordnet hat. Der Klassifikator stellt dann in der Trainingsphase seine freien Parameter – beispielsweise die freien Parameter einer Zugehörigkeitsfunktion oder die Gewichtungskoeffizienten eines Neuronalen Netzes – so ein, daß er die „bekannte“ Lernmenge möglichst gut reklassieren kann. Dies geschieht im allgemeinen so, daß er um Konzentrationen von Punkten gleicher Klassenzugehörigkeit, den sogenannten Clustern, geometrische Figuren legt. Im Falle von Kugeln würden dann beispielsweise die Durchmesser der einzelnen Kugeln so bestimmt, daß es zu möglichst keinen Überschneidungen zwischen Kugeln kommt, die unterschiedliche Klassen repräsentieren.

Die sogenannte Generalisierung des Klassifikators erfolgt über einen neuen Satz an Mustern bzw. Merkmalsvektoren, deren Klassenzuordnung a priori bekannt ist, der allerdings nicht für das vorherige Training verwendet wurde. Hier zeigt sich dann, ob die ausgewählten Muster der Lernmenge repräsentativ waren.

Sollen nach dem Training und der Generalisierung des Klassifikators unbekannte Daten klassifiziert werden, erfolgt die Berechnung des zugehöriger Merkmalsvektor bzw. Punktes im Merkmalsraum. Der Klassifikator entscheidet dann für den aktuellen Merkmalsvektor auf diejenige Klasse, in dessen Cluster von Trainingsvektoren der aktuelle Punkt abgebildet wird.

Wichtig zu erwähnen bleibt, daß aus dem Durchlauf der gesamten Verarbeitungskette bis zur Klassifikation eine erhebliche Datenreduktion resultiert. Die Dimensionen von Signaldatenraum, Merkmalsraum und Entscheidungsraum fällt in dieser Reihenfolge in der Regel deutlich ab. Wird beispielsweise die Systemantwort einer Mikrowellenbackröhre eine Sekunde lang mit einer Abtastfrequenz von 48 kHz und 16 bit Auflösung abgetastet, so fallen nach der A/D-Umsetzung insgesamt 48 kWorte an Daten an. Das Ergebnis einer unscharfen Klassifikation ist im Extremfall ein Zugehörigkeitsvektor mit zwei Zugehörigkeitswerten zu den beiden möglichen Klassen. Das Datenreduktionsverhältnis beträgt in diesem Fall 48.000:2.

Zwei bedeutende Probleme im Praxiseinsatz sind die wirklich objektive Repräsentanz der gewählten Trainingsmuster. Es muß daher besonderes Augenmerk auf eine unstrittige Gruppierung der Trainingsdaten zu semantischen Klassen gelegt werden. Bei fehlerhafter Zuordnung können eventuell Gütekriterien bei der Merkmalsauswahl nicht erfüllt



werden. Das schwerwiegendere Problem ist die falsche Klassifizierung während des praktischen Einsatzes des Mustererkennungssystems, zumal die Aitiologie dieser Falschzuordnungen nicht einfach zu ergründen ist. Geeignete graphische Darstellungen zur Beurteilung der Meßdaten und Merkmalsvektoren hinsichtlich ihrer statistischen Abweichungen sind dann hilfreich.

### **2.2.6 Wissensbasierte Interpretation**

Am Eingang des Moduls „Wissensbasierte Interpretation“ werden die einzelnen Systemzustände und Qualitäten durch eine Klassenangabe repräsentiert. Zumindest bei den in dieser Arbeit verwendeten unscharfen Algorithmen wird ein Vektor mit jeweils einem Zugehörigkeitswert für jede Klasse übergeben. Auf Grund des bereits beim Trainingsvorgang genutzten Expertenwissens, um die verschiedenen Systemzustände und Qualitäten zu unterscheiden, werden an dieser Stelle die aktuellen Meßdaten interpretiert. Am Ausgang wird somit die Klassenangabe durch die Angabe einer korrespondierenden Zustands- bzw. Qualitätsklasse dekodiert.



### 3 Fuzzy-Klassifikationskonzept

Bei einer eingehenden Betrachtung des Modells für Mustererkennungssysteme (Abbildung 2.1) ergeben sich zahlreiche Ansatzpunkte für unscharfe Methoden auf Basis der Fuzzy-Set-Theorie [Zad65]. Zum einen können die Datenvektoren mit Meßungenauigkeiten und Störungen behaftet sein, zum anderen sind die Grenzen der semantischen Klassen nicht immer eindeutig festzulegen. Konventionelle Ansätze versuchen nun scharfe eindeutige Grenzen zu definieren und Klassenstrukturen im Merkmalsraum, die sogenannten Cluster, so zu bestimmen, daß sie sich nicht überlappen. In praxi zeigt sich jedoch, daß sich immer wieder Cluster überlappen (Abbildung 3.1), und es daher selbst für die Prüfer, die zuvor die subjektiven Zustand- bzw. Qualitätsbewertungen vorgenommen haben, unmöglich ist, scharfe Grenzen zu ziehen. Dadurch sind auch die Lernmengen zum Trainieren eines Mustererkennungssystems mit einer gewissen Unsicherheit belegt, obwohl zum trainieren des Systems von einer scharfen Klassenzuordnung ausgegangen wird. Während der eigentlichen Klassifikation können und sollten die Merkmalsvektoren bzw. deren Objekte, die sie repräsentieren, jedoch in unterschiedlichem Maße gleichzeitig zu verschiedenen Klassen bzw. deren Clusterstrukturen gehören.




Abbildung 3.1: Merkmalsebene im  $R^2$  mit den beiden semantischen Klassen  $\Omega_1$  und  $\Omega_2$ . Die Klasse  $\Omega_1$  besteht wiederum aus den Clustern  $\Omega_{11}$  und  $\Omega_{12}$ .

Rein kombinatorisch ergeben sich aus den unterschiedlichen Ausprägungen von Objekten bzw. deren beschreibenden Merkmalsvektoren und den Klassen und deren Clusterstrukturen bezüglich der oben genannten Unsicherheitsdarstellung vier mögliche Kategorien [Zim95]:

- scharfe Objekte/scharfe Klassen,
- scharfe Objekte/unscharfe Klassen,
- unscharfe Objekte/scharfe Klassen,
- unscharfe Objekte/unscharfe Klassen.

Die im Rahmen dieser Arbeit entwickelten Anwendungen weisen durchgehend scharfe Meßdatenvektoren auf. Die im Merkmalsraum vorliegenden Cluster sind dagegen nicht immer eindeutig von einander zu separieren. Der verwendete Klassifikator beruht daher auf scharfen Objekten bei gleichzeitig unscharfen Klassengrenzen. Die Beurteilung eines unbekannten Objektes nach Abschluß der Lernphase ist dagegen immer unscharf. Es ist deshalb zunächst notwendig, die mathematischen Grundlagen unscharfer Mengen, soweit Sie für das Verständnis der Arbeit erforderlich sind, darzustellen.

### 3.1 Unscharfe Mengen und Zugehörigkeitsfunktionen

Mengen in der klassischen Mengenlehre werden durch Zugehörigkeitsfunktionen beschrieben, die lediglich die Werte 0 und 1 annehmen können. Ein Merkmal von scharfen Mengen ist also die für alle Elemente eindeutige Zugehörigkeitsaussage. Unscharfe Mengen werden hingegen mit Zugehörigkeitsfunktionen definiert, die auch Werte zwischen 0 und 1 annehmen können. Sie geben an, in welchem Maß ein Element zu einer entsprechenden unscharfen Menge gehört.

Eine unscharfe Menge  $A$  (fuzzy set, Fuzzy-Menge) einer Grundmenge  $X$  ist durch ihre Zugehörigkeitsfunktion  $\mu_A(x)$  definiert. Die Zugehörigkeitsfunktion  $\mu_A(x)$  bildet alle Werte  $x$  der Grundmenge  $X$  auf das Zahlenintervall  $[0, 1]$  ab:

$$\mathbf{m}_A : X \rightarrow [0, 1]. \quad (3.1)$$

$\mu_A(x)$  gibt für jeden Wert  $x$  den Zugehörigkeitsgrad von  $x$  in  $A$  an. Die Menge  $A$  wird wie folgt mathematisch formuliert:

$$A = \{(x, \mathbf{m}_A(x)) \mid x \in X\}. \quad (3.2)$$

Elemente von unscharfen Mengen werden somit durch ein Wertepaar, bestehend aus Elementwert  $x$  und Zugehörigkeitsgrad  $\mu_A(x)$  beschrieben. Um die Arbeit mit unscharfen Mengen und deren Zugehörigkeitsfunktionen zu ermöglichen, bieten sich im wesentlichen zwei Darstellungsformen an:

- Existiert nur eine endliche Anzahl von Elementen der unscharfen Menge, werden die Zugehörigkeiten der Elemente zur Menge  $A$  durch explizit durch Tabellen der Form

$$A = \{(x_1, \mathbf{m}_A(x_1)), (x_2, \mathbf{m}_A(x_2)), \dots, (x_s, \mathbf{m}_A(x_s))\} \quad (3.3)$$

mit  $S$  als der Gesamtzahl der Elemente  $x$  angegeben. Enthält die so definierte unscharfe Menge nur ein Wertepaar  $x_I, \mu_A(x_I)$  mit dem Zugehörigkeitswert  $\mu_A(x_I) = 1$ , so wird  $x_I$  als Singelton bezeichnet.  $A$  entspricht dann gleichzeitig einer scharfen Menge mit dem Element  $x_I$ .

- Bei einer unscharfen Menge mit einer unendlichen Anzahl von Elementen, die ein Kontinuum bilden, ergibt sich eine Zugehörigkeitsfunktion

$$\mathbf{m}_A(x) : X \rightarrow [0, 1]. \quad (3.4)$$

Die Eigenschaften von Fuzzy-Mengen ergeben sich aus den Kenngrößen der Zugehörigkeitsfunktion. Eine unscharfe Menge heißt „konvex“, wenn für alle Intervalle  $[x_1, x_2]$ , die im Grundbereich  $X$  liegen, der Zugehörigkeitswert  $\mu_A(x_m)$  eines im Intervall  $[x_1, x_2]$  liegenden Wertes  $x_m$  größer oder gleich dem kleinsten Wert von  $\mu_A(x_1), \mu_A(x_2)$  ist (Abbildung 3.2, Kurve 1, 2, 3):

$$\mathbf{m}_A(x_m) \geq \min[\mathbf{m}_A(x_1), \mathbf{m}_A(x_2)], \text{ für } x_1 \leq x_m \leq x_2, x_1, x_m, x_2 \in X. \quad (3.5)$$

Ist die Bedingung nicht erfüllt, so heißt die Menge nicht konvex.




Abbildung 3.2: Zugehörigkeitsfunktionen von unscharfen Mengen [Lut02]

Die „Höhe“ einer Fuzzy-Menge  $A$  ist durch das Maximum der Zugehörigkeitsfunktion  $\mu_A(x)$  bestimmt:

$$\text{height}(A) = \max\{\mathbf{m}_A(x) \mid x \in X\}. \quad (3.6)$$

Die Höhe ist eine reelle Zahl im Bereich von 0 bis 1. Wenn  $\text{height}(A) = 1$  ist, wird  $A$  als „normale“ Fuzzy-Menge bezeichnet, im anderen Falle heißt sie „subnormal“ (Abbildung

3.2, Kurve 2). Um Vergleiche besser durchführen zu können, werden im allgemeinen nur normale oder normalisierte Fuzzy-Mengen untersucht. Die „Normalisierung“

$$\mathbf{m}_{Anorm}(x) = \frac{\mathbf{m}_A(x)}{\text{height}(A)}. \quad (3.7)$$

kann ausgeführt werden, wenn  $\text{height}(A) \neq 0$  ist:




Abbildung 3.3: Zugehörigkeitsfunktion mit Kenngrößen [Lut02]

Der „Kern“ (core, Toleranz) einer Fuzzy-Menge  $A$  ist durch das Intervall gegeben, in dem die Zugehörigkeitsfunktion gleich Eins ist:

$$\text{core}(A) = \{x \mid x \in X, \mathbf{m}_A(x) = 1\}. \quad (3.8)$$

Der „Support“ (Stützmenge, Einflußbreite) einer Fuzzy-Menge ist der Bereich von  $x$ , für den die Zugehörigkeitsfunktion  $\mu_A(x)$  größer Null ist:

$$\text{supp}(A) = \{x \mid x \in X, \mathbf{m}_A(x) > 0\}. \quad (3.9)$$

Kern und Support sind scharfe Mengen.

Prinzipiell können viele unterschiedliche Kurvenformen für Zugehörigkeitsfunktionen in der Fuzzy-Logik eingesetzt werden. Es haben sich hauptsächlich zwei Funktionstypen bewährt:

- Stückweise stetige, lineare Funktionen (Abbildung 3.4 a)),
- Quadratische Funktionen und e-Funktionen (Abbildung 3.4 b)).




Abbildung 3.4: Funktionsgraphen für unscharfe Mengen, a) Fuzzy-Menge mit Trapezfunktion, b) geglättete Zugehörigkeitsfunktion [Stö95]

### 3.2 Zugehörigkeitsfunktion mit gewichtetem Distanzmaß

Legt man Abbildung 3.5 Personen vor, die sich gewöhnlich nicht mit mathematisch-technischen Fragestellungen beschäftigen, zeigt sich, daß der Endpunkt des Vektors **m** nahezu immer der Punktwolke (Cluster)  $\Omega_2$  zugeordnet wird. In einer anschließenden Diskussion über Ihre Entscheidung offenbart sich, daß die Beurteilung über die Zugehörigkeit des Punktes erstens durch den Abstand zum Schwerpunkt und zweitens aufgrund der Form des Clusters erfolgt.




Abbildung 3.5: Merkmalsebene mit den Klassen  $\Omega_1$  und  $\Omega_2$

Die Bestimmung der Ähnlichkeit eines Objektes zu einer zuvor gelernten Referenzklasse kann somit über die Festlegung einer geeigneten Metrik im Merkmalsraum geschehen. Die Einflüsse aus der Klassifikationsunsicherheit und der geometrischen Klassenstruktur können durch die Anwendung eines mit der klassen- und hauptachsenspezifischen Stichprobenstreuung gewichteten Abstandsklassifikators auf Basis einer Fuzzy-Zugehörigkeitsfunktion berücksichtigt werden.

Die häufig anzutreffende konvexe, hyperelliptische, einfachzusammenhängende und nur aus einem Cluster bestehende Klassenstruktur mit beliebiger Orientierung im  $N$ -dimensionalen Merkmalsraum  $R^N$  (Abbildung 3.5) wird durch den im folgenden beschriebene unscharfen Abstandsklassifikator sehr gut abgebildet. Methoden zur Vermeidung eventueller Klassifikationsschwächen durch die algorithmische Beschränkung auf Klassenstrukturen mit nur einem hyperelliptischen Cluster werden in Kapitel 5 dieser Arbeit vorgestellt.

Voraussetzung für die Entwicklung eines Fuzzy-Klassifikators, der die o. g. Bedingungen erfüllt, ist die Definition einer entsprechenden Zugehörigkeitsfunktion mit integriertem gewichteten Abstandsmaß. Die Struktur der Klasse ist dabei die Basis zur Bestimmung aller freien Parameter dieser Zugehörigkeitsfunktion. In [Str93] wird die geglättete unimodale Zugehörigkeitsfunktion

$$\mathbf{m}_k(\mathbf{m}) = \frac{1}{1 + \frac{1}{t} d_{km}^2} \quad \text{mit } k = 1, \dots, K \quad \text{und } t > 0 \quad (3.10)$$

nach Abbildung 3.4 b) vorgeschlagen. Diese Funktion drückt die Zugehörigkeit des  $N$ -dimensionalen Merkmalsvektors  $\mathbf{m}$  zur Klasse  $\Omega_k$  ( $k = 1, \dots, K$ ) mit Hilfe des skalaren, reellen Abstandsmaßes  $d_{km}$  aus. Für Mehrklassenprobleme ( $K > 1$ ) werden die ermittelten  $K$  Klassenzugehörigkeiten zu einem  $K$ -dimensionalen Vektor zusammengefaßt.

### 3.2.1 Distanzmaß auf Basis des MAHALANOBIS-Abstandes

Die Bestimmung der funktionalen Ähnlichkeit eines Merkmalsvektors  $\mathbf{m}$  zu einer zuvor gelernten Referenzklasse erfolgt in Gleichung (3.10) mittels der Festlegung eines geeigneten Distanzmaßes  $d_{km}$  im multidimensionalen Merkmalsraum. Die Bestimmung der freien Parameter der Gleichung (3.10) als beschreibende klassenspezifische Größen beschränkt sich somit auf die Berechnung des Abstandsmaßes  $d_{km}$  aus den Daten der aufgenommenen Lernmenge und der Festlegung des Parameters  $t$ .



Um aus dem Merkmalsraum einen metrischen Raum im Sinne der Funktionalanalysis zu erzeugen, muß das Distanzmaß  $d_{km}$  die folgenden Eigenschaften erfüllen [Bro98]:

1. das Axiom der Positivität  $d_{km} > 0$ ,
  2. das Axiom der Identität  $d_{kk} = 0$ ,
  3. das Axiom der Symmetrie  $d_{km} = d_{mk}$  und
  4. das Axiom der Dreiecksungleichung  $d_{km} \leq d_{kz} + d_{zm}$ .
- (3.11)

Aus der Literatur [Spä75], [Zim95], [Bro98] stehen zahlreiche Abstandsmaße zur Verfügung. Wie zuvor jedoch schon erwähnt, sollte das zu wählende Distanzmaß die klassen- und hauptachsenspezifischen Stichprobenstreuungen der jeweiligen Cluster berücksichtigen und dadurch verschiedene am Rand eines Clusterellipsoides  $k$  gelegene Merkmalsvektoren  $\mathbf{m}$  mit einem ähnlichen Abstand zum Schwerpunkt  $\mathbf{r}_k$  des Clusters  $k$  versehen. Das häufig eingesetzte Abstandsmaß der euklidischen Metrik

$$d_{km} = |\mathbf{m} - \mathbf{r}_k| = \sqrt{\sum_{n=1}^N (m_n - r_{kn})^2} \quad (3.12)$$

eignet sich zur Erfüllung der obigen Forderung nur in Sonderfällen, da es sämtliche Richtungen des Merkmalsraumes gleich bewertet.

Eine richtungsabhängige Gewichtung des euklidischen Abstandes nach (3.12) über die Streuung der Stichprobenvektoren eines Clusters in der jeweiligen Raumachse ermöglicht dagegen die Vorgabe eines vergleichbaren Distanzmaßes für die in gleichem Maße randständigen Merkmalsvektoren. Aus diesem Grund basiert der implementierte unscharfe Klassifikationsalgorithmus, der im Rahmen dieser Arbeit entstanden SubVI-Bibliothek, auf einem von BEHR und STRACKELJAN [Str93] vorgeschlagenen Abstandsklassifikator mit der Metrik

$$d_{km}^2 = \sum_{n=1}^N \frac{1}{I_{kn}} ((\mathbf{m} - \mathbf{r}_k) \cdot \tilde{\mathbf{e}}_{kn})^2 \quad \text{mit} \quad I_{kn} \neq 0, \quad (3.13)$$

welche identisch mit dem in [Mah36] abgeleiteten Distanzmaß

$$d_{Mkm}^2 = (\mathbf{m} - \mathbf{r}_k)^T \mathbf{C}_k^{-1} (\mathbf{m} - \mathbf{r}_k) \quad (3.14)$$

ist, sofern die Determinante der Stichprobenkovarianzmatrix  $\mathbf{C}_k$  der  $k$ -ten Klasse ungleich 0 ist.

Der Bezugspunkt für die Berechnung des Abstandes nach Gleichung (3.13) und der auch augenscheinlichste Lageparameter einer Klasse mit hyperelliptischer Clusterstruktur im

$N$ -dimensionalen Merkmalsraum ist der sogenannte Schwerpunktvektor oder auch Clusterprototyp

$$\mathbf{r}_k = \frac{1}{S_k} \sum_{s=1}^{S_k} \mathbf{m}_{ks} \quad \text{mit } k=1, \dots, K, \quad s=1, \dots, S_k \quad \text{und} \quad S_k \neq 0. \quad (3.15)$$

Darin bedeutet  $\mathbf{m}_{ks}$  den zur  $k$ -ten Klasse gehörigen Merkmalsvektor mit der Stichprobennummer  $s$  ( $s=1, \dots, S_k$ ) in einem durch die Einheitsvektoren  $\mathbf{e}_n$  ( $n=1, \dots, N$ ) aufgespannten kartesischen Koordinatensystem.

Die Struktur der aus den Merkmalsvektoren  $\mathbf{m}_{ks}$  ( $k=1, \dots, K$  und  $s=1, \dots, S_k$ ) aufgebauten Lernmenge unter Berücksichtigung der möglicherweise vorhandenen statistischen Abhängigkeiten spiegelt sich in der klassenspezifischen, symmetrischen, positiv semidefiniten Stichprobenkovarianzmatrix

$$\mathbf{C}_k = \frac{1}{S_k - 1} \sum_{s=1}^{S_k} (\mathbf{m}_{ks} - \mathbf{r}_k)(\mathbf{m}_{ks} - \mathbf{r}_k)^T \quad \text{mit } k=1, \dots, K \quad \text{und} \quad S_k \neq 1 \quad (3.16)$$

und den Elementen

$$c_{kij} = \frac{1}{S_k - 1} \sum_{s=1}^{S_k} (m_{ksj} - r_{kj})(m_{ksi} - r_{ki}) \quad (3.17)$$

wider.

In (3.16) und (3.17) bedeuten  $S_k$  die Anzahl der zur  $k$ -ten Klasse gehörigen Merkmalsvektoren  $\mathbf{m}_{ks}$ ,  $m_{ksi}$ ,  $m_{ksj}$  die  $i$ -te bzw.  $j$ -te Komponente des  $s$ -ten Merkmalsvektors  $\mathbf{m}_{ks}$  der  $k$ -ten Klasse. Ferner gilt für die Stichprobenkovarianzmatrix

$$\mathbf{C}_k = \mathbf{C}_k^T \quad (\text{Symmetrie}) \quad \text{und} \quad c_{kii} = \mathbf{s}_i^2 \quad (3.18)$$

Hierin stellen die Diagonalelemente  $c_{kii}$  das Quadrat der empirischen Streuung  $\mathbf{s}$  (Standardabweichung) die sogenannte Empirische Varianz um den Klassenprototypen bzw. den Schwerpunktvektor  $\mathbf{r}_k$  dar.

Weiterhin ist unmittelbar einsichtig, daß die Berechnung des Abstandsmaßes (3.13) am einfachsten in einem an die Lage des Clusters angepaßten Koordinatensystems erfolgen kann. Der Anschauung entsprechend, sollten die Basisvektoren dieses Koordinatensystems durch die Hauptachsen des Klassenellipsoids festgelegt werden. Dies führt auf die Hauptachsentransformation der reellen symmetrischen Stichprobenkovarianzmatrix der  $k$ -Klasse

$$\mathbf{L}_k = \mathbf{Q}_k^T \mathbf{C}_k \mathbf{Q}_k \quad (3.19)$$

Darin sind  $\mathbf{L}_k$  eine Diagonalmatrix

$$\mathbf{L}_k = \begin{pmatrix} \mathbf{I}_{k1} & 0 & \cdots & 0 \\ 0 & \mathbf{I}_{k2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{I}_{kN} \end{pmatrix}, \quad (3.20)$$

deren Elemente die Eigenwerte von  $\mathbf{C}_k$  sind, und  $\mathbf{Q}_k$  eine orthogonale Matrix, deren Spalten die zu den Eigenwerten  $\mathbf{I}_{kn}$  gehörenden normierten Eigenvektoren  $\tilde{\mathbf{e}}_{kn}$  darstellen. Zur Bestimmung der Eigenwerte  $\mathbf{I}_{kn}$  und der Eigenvektoren  $\tilde{\mathbf{e}}_{kn}$  ist das spezielle Eigenwertproblem

$$\mathbf{C}_k \tilde{\mathbf{e}}_{kn} = \mathbf{I}_{kn} \tilde{\mathbf{e}}_{kn} \quad \text{bzw.} \quad (\mathbf{C}_k - \mathbf{I}_{kn} \mathbf{E}) \tilde{\mathbf{e}}_{kn} = \mathbf{0} \quad (3.21)$$

zu lösen. Diese Gleichung stellt ein homogenes lineares Gleichungssystem dar. Notwendige Bedingung für die Existenz nichttrivialer Lösungen

$$\tilde{\mathbf{e}}_{kn} \neq \mathbf{0} \quad (3.22)$$

dieses Gleichungssystems ist, daß die charakteristische Matrix  $(\mathbf{C}_k - \mathbf{I}_{kn} \mathbf{E})$  singular ist

$$\det(\mathbf{C}_k - \mathbf{I}_{kn} \mathbf{E}) = 0. \quad (3.23)$$

Die zu den verschiedenen Eigenwerten  $\mathbf{I}_{kn}$  nichttrivialen Lösungen  $\tilde{\mathbf{e}}_{kn}$  sind orthogonal, d. h., es gilt

$$\tilde{\mathbf{e}}_{ki}^T \tilde{\mathbf{e}}_{kj} = \begin{cases} 0 & \text{für } i \neq j, \\ 1 & \text{für } i = j, \end{cases} \quad i, j = 1, \dots, N. \quad (3.24)$$

Letztendlich ergibt sich für Gleichung (3.10)

$$\mathbf{m}_k(\mathbf{m}) = \frac{1}{1 + \frac{1}{t} \sum_{n=1}^N \frac{1}{\mathbf{I}_{kn}} ((\mathbf{m} - \mathbf{r}_k) \tilde{\mathbf{e}}_{kn})^2} \quad \text{mit } k = 1, \dots, K \quad \text{und} \quad t, \mathbf{I}_{kn} > 0. \quad (3.25)$$

Der noch freie Parameter  $t$  bestimmt als multiplikativer Faktor die Lage des Wendepunktes der Funktion in Richtung der Klassenhauptachsen als Vielfaches der Varianz  $\mathbf{I}_k$ . In [Str93] wird  $t = 3$  vorgeschlagen, weil damit die Wendepunktcoordinate in Hauptachsenrichtung gerade mit dem Wert der Streuung zusammenfällt.

Die Bestimmung der freien Parameter der Zugehörigkeitsfunktion als beschreibende klassenspezifische Größen beschränkt sich also auf die Berechnung der freien Parameter

des Abstandsmaßes nach (3.13). Sie werden in der Lernphase mit Hilfe der Stichprobenmatrix, bestehend aus den Merkmalsvektoren der vermessenen Referenzobjekte mit bekannter Klassenzugehörigkeit, ermittelt.

---

**Algorithmus:** Lernen
 

---

**Gegeben:** Stichprobenmatrix der Merkmalsvektoren mit Klassenlabel, aktuelle Merkmalskombination  $U_j^N$

**Gesucht:** Klassenprototyp  $\mathbf{r}_k$ , Eigenwerte  $\mathbf{I}_{kn}$  und Eigenvektoren  $\tilde{\mathbf{e}}_{kn}$

1. Für jede semantische Klasse  $\Omega_k$  führe aus:

1.1 Berechne den Klassenprototypen (Schwerpunktvektor)  $\mathbf{r}_k$  im  $R^N$

1.2 Berechne die Stichprobenkovarianzmatrix  $\mathbf{C}_k$ .

1.3 Berechne die zu  $\mathbf{C}_k$  gehörenden Eigenwerte  $\mathbf{I}_{kn}$  und Eigenvektoren  $\tilde{\mathbf{e}}_{kn}$

2. Speichere die Ergebnisse

---

Nach erfolgtem Lernvorgang ist das Mustererkennungssystem – eine geeignete Merkmalskombination  $U_j^N$  vorausgesetzt – in der Lage weitere dem System unbekannte Merkmalsvektoren zu klassifizieren. Die Klassifikation erfolgt durch Einsetzen des Merkmalsvektors  $\mathbf{m}$  in die Zugehörigkeitsfunktionen  $\mu_k(\mathbf{m})$  der  $k$  semantischen Klassen.

---

**Algorithmus:** Lernen
 

---

**Gegeben:** aktueller Merkmalsvektor  $\mathbf{m}$ ,

Klassenprototypen  $\mathbf{r}_k$ , Eigenwerte  $\mathbf{I}_{kn}$  und Eigenvektoren  $\tilde{\mathbf{e}}_{kn}$

**Gesucht:** Zugehörigkeitsvektor  $\mu(\mathbf{m})$

1. Für jede semantische Klasse  $\Omega_k$  führe aus:

1.1 Berechne das Quadrat des Distanzmaßes  $d_{km}$

1.2 Setze  $(d_{km})^2$  in die Zugehörigkeitsfunktion  $\mu_k$  ein und

1.3 Speichere das Ergebnis im Zugehörigkeitsvektor  $\mu(\mu_1(\mathbf{m}), \dots, \mu_K(\mathbf{m}))$

---

Mit der Berechnung des Zugehörigkeitsvektors  $\mu(\mathbf{m})$  zum Merkmalsvektor  $\mathbf{m}$  ist allerdings keinesfalls schon eine Entscheidung über die Klassenzugehörigkeit getroffen, da der Vektor  $\mu(\mathbf{m})$  Zugehörigkeitswerte  $\mu_k(\mathbf{m})$  für jede semantische Klasse  $k$  enthält. Der Übergang von unscharfen Zugehörigkeiten zu einer scharfen Entscheidung, der sogenannten Defuzzifizierung, spielt z. B. beim Einsatz von Fuzzy-Systemen in der

automatischen Qualitätskontrolle eine wichtige Rolle, da der Anwender letztendlich an einer scharfen Aussage über den fehlerbehafteten bzw. fehlerfreien Zustand des Produktes interessiert ist. Ein unmittelbar naheliegendes Kriterium mit dessen Hilfe eine Entscheidung über die Klassenzuweisung getroffen werden kann, ist die Bestimmung des maximalen Zugehörigkeitswertes

$$\hat{\mu}_s = \max_k (\mu_k(\mathbf{m})) \quad \text{mit } k = 1, \dots, K \quad (3.26)$$

des Merkmalsvektors  $\mathbf{m}$ . Die Größe  $\hat{\mu}_s$  wird häufig als Hauptzugehörigkeit bezeichnet. Im Fall von gleichen Zugehörigkeiten kann eine Entscheidung über die Klassenzugehörigkeit des Objektes z. B. auf Grund von Auftrittswahrscheinlichkeiten der einzelnen Klassen erfolgen.



## 4 Klassifikatorbezogene Merkmalsauswahl

Da gerade in der Schwingungsüberwachung durch die unaufhörlich steigenden Abtastraten und Frequenzauflösungen moderner Meßsysteme die Dimensionen der Signal-datenräume immens ansteigen, stehen bei der Beurteilung von Schwingungssignalen i. a. sehr hochdimensionale Merkmalsvektoren zur Verfügung. Grundsätzlich weist der in Kapitel 3 beschriebene Algorithmus für Klassifikationsaufgaben zwar keine Dimensionsbeschränkung auf, doch steigt der Klassifikationsaufwand mit der Zahl der Merkmale erheblich an. Daneben kann eine der eigentlichen Klassifikation vorausgehende Berechnung von Sekundärmerkmalen den Rechenaufwand soweit steigern, daß eine on-line Klassifikation im vollständigen Merkmalsraum  $R^N$  nicht mehr möglich ist.

Die Merkmalsauswahl verfolgt somit das Ziel, die signifikanten Merkmale in bezug auf die anschließend im Klassifikator durchzuführende Unterscheidung verschiedener Systemzustände bzw. Qualitäten vorzubereiten. Die Signifikanz der ausgewählten Merkmale zeigt sich, wenn die gefundenen Clusterstrukturen der Lernmenge im Merkmalsraum  $R^N$  oder  $U^M$  in direkter Übereinstimmung zur semantischen Klasseneinteilung stehen. Mit  $R^N$  wird in diesem Zusammenhang ein Raum bezeichnet, in dem eine Metrik nach (3.11) definiert ist und der durch die Merkmalsvektoren der Dimension  $N$  aufgespannt wird. Mit  $U^M$  wird ein Unterraum von  $R^N$  bezeichnet, in dem die gleiche Metrik definiert ist, der jedoch durch reduzierte Merkmalsvektoren der Dimension  $M=N$  aufgespannt wird. Existieren mehrere Unterräume zu  $R^N$ , so ist zweckmäßigerweise derjenige Raum auszuwählen, der die Klassifikation mit der geringsten Fehlerwahrscheinlichkeit erlaubt.

Aus welchen Merkmalen sich die Unterräume, die eine zuverlässige Unterscheidung gestatteten, zusammensetzen, ist gewöhnlich nicht einfach zu ermitteln. Auch heute werden zu diesem Zweck oft noch lange Versuchsreihen durchgeführt, um aus der Vielzahl von Signalverarbeitungsverfahren einige erfolgversprechende auszuwählen. Meßtechniker und Prüfer arbeiten dabei häufig empirisch, wobei ihre Erfahrung oft das wichtigste Hilfsmittel darstellt, um die signifikanten Merkmale in den oft hochdimensionalen Suchräumen zu finden. Die Folge dieser Vorgehensweise ist eine komplette oder zumindest eine nahezu vollständige Trennung der Teilsysteme Merkmalsauswahl und Klassifikator. Diese Trennung der Teilsysteme wird häufig mit einem reduzierten Rechenaufwand begründet. Mit der enormen Steigerung der verfügbaren Rechenleistung ist dieses Argument heute jedoch nicht mehr stichhaltig.

Aus diesem Grund wird im Rahmen dieser Arbeit ein Konzept zur Vereinigung von Merkmalsauswahl und Klassifikation, das in [Str93] beschrieben ist, an die gestiegenen Rechnerleistungen angepaßt. Diese sogenannten „Wrapper“-Ansätze verwenden bereits für die Gütebewertung innerhalb der Merkmalsauswahl den auch später zur Klassifikation verwendeten Klassifikator. Da das eingesetzte Gütekriterium unmittelbar mit dem gewählten Klassifikationsalgorithmus zusammenhängt, erfüllen die so ausgewählten Merkmale in jedem Fall die mathematischen Vorgaben und algorithmischen Einschränkungen bezüglich der Clusterstrukturen im Unterraum  $U^M$ .

Grundsätzlich können aber sowohl klassifikatorabhängige als auch klassifikatorunabhängige Gütekriterien unterschieden werden. Die klassifikatorabhängigen besitzen gegenüber den klassifikatorunabhängigen Methoden neben dem o. g. Vorteil die positive Eigenschaft, daß mit ihnen eine konkrete Aussage über die Fehlerwahrscheinlichkeiten bei der praktischen Anwendung eines Klassifikators möglich ist. Die klassifikatorunabhängigen Methoden versuchen dagegen nur auf Basis der bereitgestellten Lernmenge Gütwerte zu berechnen. Sie gehen generell davon aus, daß die Fehlerwahrscheinlichkeit sinkt, wenn die Klassen im Merkmalsraum einen möglichst großen Interklassenabstand aufweisen. Sie definieren daher meist eine Form von Abstandsmaß zwischen den Klassen (siehe auch [Win81], [Tra91], [Str93], [Ott98]). Der entscheidende Nachteil der klassifikatorunabhängigen Methoden ist allerdings, daß die ermittelten Merkmale nicht unbedingt für das Gesamtsystem geeignet sein müssen.

Jede Methode – ungeachtet welcher Kategorie – beinhaltet jedoch

1. ein Gütekriterium,
2. eine Suchstrategie und
3. ein Abbruchkriterium.

Somit werden im nächsten Abschnitt zunächst die zwei in dieser Arbeit verwendeten Gütekriterien dargestellt. Weitere Gütemaße findet man in [Str93] und [Ott98].

## 4.1 Gütekriterien der klassifikatorbezogenen Merkmalsauswahl

### 4.1.1 Die Reklassierungsgüte

Auf der Basis einer mit Klassenlabels versehenen Lernmenge – jeder Merkmalsvektor wurde durch einen Lehrer eindeutig einer semantischen Klasse zugeordnet – läßt sich ein Gütekriterium formulieren, indem die Merkmalsvektoren der Lernmenge vom jeweiligen Klassifikationsalgorithmus reklassiert werden müssen.



Das Verhältnis

$$G_R^M = \frac{S_R}{S}, \quad S \neq 0 \quad (4.1)$$

aus der Anzahl  $S_R$  der gemäß der vergebenen semantischen Klassen korrekt klassifizierten Merkmalsvektoren zur Anzahl  $S$  der insgesamt untersuchten Merkmalsvektoren ergibt die Reklassierungsgüte  $G_R^M$ . Der hochgestellte Index gibt die Dimension der Suchbasis an. Da die Lernmenge in der Regel alle verfügbaren Informationen über das zu beurteilende Objekt beinhaltet, dient dieses Gütemaß, das die Lernmenge direkt in die Berechnungen mit einbezieht, zur Steuerung der im nächsten Abschnitt beschriebenen Suchstrategie der klassifikatorbezogenen Merkmalsauswahl. Ein weiterer Vorteil dieses Gütemaßes besteht darin, daß sich schon bei einem geringen Stichprobenumfang  $S < 50$  aussagekräftige Werte für  $G_R^M$  ermitteln lassen. Insgesamt wird also innerhalb der Merkmalsauswahl ein möglichst geringer Reklassierungsfehler

$$G_{RF}^M = 1 - G_R^M = 1 - \frac{S_R}{S} \quad \text{mit} \quad S \neq 0 \quad (4.2)$$

angestrebt.

Die Entscheidung über die Zuweisung eines Merkmalsvektors zu einer semantischen Klasse wird hier durch die bereits in Abschnitt 3.2.1 vorgestellte Hauptzugehörigkeit

$$\hat{\mathbf{m}}_s = \max_k \mathbf{m}_k(\mathbf{m}_s), \quad k = 1, \dots, K \quad (4.3)$$

getroffen. Als korrekt klassifizierte Merkmalsvektoren gelten diejenigen, deren Indizes ihrer Hauptzugehörigkeiten mit dem Klassenlabel der Lernmenge übereinstimmen.

#### 4.1.2 Die mittlere Zugehörigkeitsdifferenz

Die Klassifikationsentscheidung gewinnt an Eindeutigkeit, wenn der mittlere Abstand, gebildet aus den gemittelten Differenzen der Klassenzugehörigkeit  $\mathbf{m}_k$  und der größten Nebenzugehörigkeit der korrekt klassifizierten Merkmalsvektoren  $S_R$ , zunimmt. Aus dieser Tatsache läßt sich in der Form

$$\bar{G}_D = \frac{1}{S_R} \sum_{k=1}^K \sum_{s=1}^{S_{kR}} \mathbf{m}_k(\mathbf{m}_s) - \max_l (\mathbf{m}_l(\mathbf{m}_s)) \quad \text{mit} \quad l = 1, \dots, K \setminus \{k\}, \quad S_R \neq 0 \quad (4.4)$$

eine einfache Maßzahl für den Interklassenabstand ableiten. Bei der Verwendung von  $\overline{G}_d$  muß allerdings beachtet werden, daß sich für kleine Hauptzugehörigkeitswerte natürlich auch kleine Werte für einzelne Zugehörigkeitsdifferenzen ergeben.

## 4.2 Suchstrategien zur Merkmalsauswahl

Die Suchstrategie innerhalb einer Merkmalsauswahl legt fest, welche Merkmalskombinationen mittels der zuvor dargestellten Gütekriterien zu untersuchen sind. Grundsätzlich lassen sich die vollständige Suche, die sequentielle Abwärtsselektion und die sequentielle Vorwärtsselektion unterscheiden.

Die vollständige Suche erfordert die rechentechnische Beurteilung aller  $\binom{N}{M}$  nichtleeren Untermengen für  $M=N$ . Ist die Anzahl der zu selektierenden Merkmale  $M$  bereits festgelegt (z. B. durch technische Randbedingungen), so müssen dennoch für ein DFT-Spektrum mit 400 diskreten Frequenzlinien und einer Beschränkung auf Untermengen mit 10 Merkmalen  $1,5 \cdot 10^{25}$  Kombinationen untersucht werden. Abgesehen von kleinen Werten für  $N$  ist die vollständige Suche somit im allgemeinen nicht realisierbar.

Im Rahmen der sequentiellen Rückwärtsselektion wird ausgehend von der Gesamtmenge  $M=N$  jeweils das Merkmal mit der geringsten Reduktion des Gütemaßes entfernt. Die Rückwärtsselektion ist somit ein suboptimales Verfahren, dessen Rechenaufwand jedoch gegenüber der in dieser Arbeit verwendeten Suchstrategie, der sequentiellen Vorwärtssuche, höher ist, da mit allen Merkmalen begonnen wird.

Zur detaillierten Beschreibung der sequentiellen Vorwärtssuche und der in diesem Zusammenhang verwendeten Merkmalsmengen ist es notwendig, eine einheitliche Terminologie einzuführen. Es sollen für die weiteren Ausführungen folgende Bezeichnungen gelten:

- $U$  : Menge beliebiger Merkmalskombinationen,
- $U^M$  : Menge beliebiger Merkmalskombinationen aus  $M$  Merkmalen,
- $U_j^M$  : bestimmte, mit  $j$  numerierte Merkmalskombination auf der Basis von  $M$  Merkmalen,
- $U_0^M$  : Menge aller möglichen Kombinationen mit  $M$  Merkmalen,
- $\tilde{U}_0^M$  : nach beliebigem Gütemaß sortierte Menge aller möglichen Kombinationen mit  $M$  Merkmalen,
- $\hat{U}^M$  : Menge der Kombinationen mit  $M$ -Merkmalen oberhalb eines Grenzwertes eines beliebigen Gütemaßes.

#### 4.2.1 Sequentielle Vorwärtssuche mit beschränkt optimaler Merkmalsauswahl

Beginnend bei einem oder wenigen Merkmalen, wird die Anzahl der aktuell betrachteten Merkmale  $M$  schrittweise erhöht. Die sequentielle Vorwärtsselektion ist allerdings genau wie die sequentielle Abwärtsselektion eine suboptimale Methode, welche nicht garantiert, daß die für die Klassifikation beste Merkmalskombination gefunden wird. Da aber eine vollständige Suche aufgrund der sehr langen Rechenzeiten nicht durchführbar ist und eine Untermenge  $U^M$ , ermittelt durch einen Auswahlprozeß basierend auf der vorherigen Elimination von Einzelmerkmalen, nicht annähernd an die Gütewerte der besten Untermenge heran kommt, wird in [Str93] ein Verfahren zur suboptimalen Merkmalsauswahl vorgeschlagen, das zunächst alle

$$\binom{N}{2} = \frac{N!}{2!(N-2)!} \quad (4.5)$$

Zweierkombinationen berechnet. Aus dieser vollständigen Suchbasis  $U_0^2$  kann dann entweder durch die Angabe eines Grenzwertes für die Reklassierungsgüte  $G_R^2$  oder durch die Vorgabe der maximalen Anzahl an Listenelementen eine nach  $G_R^2$  sortierte Bestenliste  $\hat{U}_0^2$  der leistungsfähigsten Zweierkombinationen erzeugt werden. Die Merkmalskombinationen  $U_j^2$  dieser Bestenliste werden im nächsten Schritt nacheinander mit allen noch nicht in der jeweiligen Merkmalskombination enthaltenen Merkmalen kombiniert. Durch die Bewertung mit dem Gütemaß  $G_R^3$  wird wieder eine sortierte Bestenliste  $\hat{U}^3$  erzeugt, die allerdings nicht mehr auf der gesamten Suchbasis  $U_0^3$  beruht.

Die Abarbeitung der jeweiligen Bestenlisten wird so lange wiederholt, bis die Dimension der ermittelten Untermenge  $\hat{U}^M$ , der vorgegebenen maximalen Merkmalsanzahl  $\hat{M}$  entspricht. Der große Vorteil dieser Vorgehensweise liegt in der unmittelbaren Steuerbarkeit der Rechenzeit durch die Vorgabe der Elementanzahl in der „Bestenliste“.

Da die Rechenleistung der PC-Systeme in den letzten Jahren enorm gestiegen ist und dieser Trend auch in Zukunft anhalten wird, ist es nach Meinung des Autors sinnvoll, das vorgestellte suboptimale Auswahlverfahren an diese Entwicklung anzupassen. Dazu wird vorgeschlagen die Dimension des Suchraumes, bis zu der eine vollständige Suche durchgeführt werden soll, frei wählbar zu gestalten. Gerade bei Systemen mit kleineren Merkmalsanzahlen  $N$  können dadurch die Klassifizierungsergebnisse unter Umständen weiter verbessert werden.

---

**Algorithmus: Merkmalsauswahl**


---

**Gegeben:** Stichprobenmatrix der  $S$  Merkmalsvektoren mit Klassenlabels  $k=1, \dots, K$ , max. Dimension  $\hat{M}_0$  der Untermengen  $U_0^M$  der optimalen Merkmalsauswahl, max. Dimension  $\hat{M}$  der suboptimalen Merkmalsauswahl, minimale Reklassierungsgüte  $\tilde{G}_R$

**Gesucht:** (sub-)optimale Bestenliste  $\hat{U}^M$  oberhalb von  $\tilde{G}_R$

1. Setze  $M = 1$

**2. Wiederhole**

2.1 Falls  $M \leq \hat{M}_0$  führe aus:

2.1.1 Für alle Merkmalskombination  $U_0^M$  führe aus:

2.1.1.1 Starte den Algorithmus „Lernen“ für  $U_j^M$ .

2.1.1.2 Starte den Algorithmus „Klassifikator“ für alle reduzierten  $S$  Merkmalsvektoren mit der Merkmalskombination  $U_j^M$  und schreibe die Zugehörigkeitswerte in ein Array

2.1.1.3 Berechne die Gütewerte  $G_R^M$  und  $\bar{G}_D^M$  für  $U_j^M$  mit Hilfe des Zugehörigkeitsarrays

2.1.1.4 Für  $G_R^M \geq \tilde{G}_R$ , schreibe  $U_j^M$  und die Gütewerte in  $\hat{U}$ .

2.2 Falls  $M > \hat{M}_0$  führe aus:

2.2.1 Für alle Merkmalskombination  $\hat{U}^{M-1} \cup U_j^{M-\hat{M}_0}$  führe aus:

2.2.1.1 Starte den Algorithmus „Lernen“ für  $\hat{U}^{M-1} \cup U_j^{M-\hat{M}_0}$ .

2.2.1.2 Starte den Algorithmus „Klassifikator“ für alle reduzierten  $S$  Merkmalsvektoren mit der Merkmalskombination  $\hat{U}^{M-1} \cup U_j^{M-\hat{M}_0}$  und schreibe die Zugehörigkeitswerte in ein Array

2.2.1.3 Berechne die Gütewerte  $G_R^M$  und  $\bar{G}_D^M$  für  $\hat{U}^{M-1} \cup U_j^{M-\hat{M}_0}$  mit Hilfe des Zugehörigkeitsarrays

2.2.1.4 Für  $G_R^M \geq \tilde{G}_R$ , schreibe  $\hat{U}^{M-1} \cup U_j^{M-\hat{M}_0}$  und die Gütewerte in  $\hat{U}$ .

2.3 Erhöhe  $M$  um eine Dimension auf  $M+1$ .

3. Bis  $M > \hat{M}$ .

4. Sortiere  $\hat{U}$  aufsteigend nach  $M$  und  $G_R^M$ .

---

### 4.3 Merkmalskombinationen ohne elliptische Clusterstrukturen

Clusteranalyseverfahren sollen beliebig geformte Gebiete mit räumlichen Konzentrationen von Merkmalsvektoren (Gebiete hoher Wahrscheinlichkeitsdichten) in beliebig hochdimensionalen Merkmalsräumen detektieren. Diese Gebiete hoher Konzentrationen, auch Cluster genannt, werden in Fuzzy-Prototyp-Klassifikatoren durch die Statistiken erster Ordnung, also einem Prototypen (Cluster-Zentrum, Schwerpunktvektor) und einer Kovarianzmatrix (Verteilung der Merkmalsvektoren um den Prototypen) beschrieben. In vielen echten Anwendungen sind dem Clusteranalyse-Verfahren zwar die Klassenanzahl, aber weder die Anzahl der klassenbeschreibenden Prototypen, noch deren zugehörigen Kovarianzmatrizen bekannt. Mehr noch, in der Regel kann das Clusterverfahren noch nicht einmal davon ausgehen, daß die Cluster normalverteilt vorliegen.

Der nach Gleichung (3.25) von STRACKELJAN und BEHR vorgeschlagene Fuzzy-Prototyp-Klassifikator setzt – wie auch in [Ott98] und [Bun95] erkannt – voraus, daß

1. jede Klasse nur durch einen einzigen Prototypen beschrieben wird,
2. die Merkmalsvektoren in Form einer multivariaten Normalverteilung um den Klassenprototypen angeordnet sind,
3. zur Berechnung des einzigen Prototypen einer semantischen Klasse die Stichprobenvektoren a priori alle mit der gleichen Gewichtung eingehen müssen.

Als Konsequenz dieser einschränkenden Voraussetzungen ist der Abstandsklassifikator nach (3.25) lediglich in der Lage, Muster mit einfachzusammenhängenden hyperellipsoiden Strukturen im Merkmalsraum zu erkennen. Es ist aber sehr wohl möglich, daß die Verteilung der Merkmalsvektoren für einzelne Merkmalskombinationen von dieser vorgegebenen Struktur mehr oder weniger stark abweicht. Ein Grund dafür kann beispielsweise eine a priori unzureichende oder fehlerhafte Information über die Klassenanzahl und -verteilung sein, so daß für identische semantische Klassen nichtzusammenhängende Clusterstrukturen im Merkmalsraum entstehen (Abbildung 4.1 a)). Weiterhin können die zur Merkmalserzeugung verwendeten physikalisch-mathematischen Methoden zu nicht zusammenhängenden Gebieten oder zu Clustern mit stark konkaven Strukturen führen (Abbildung 4.1 b)). Wie STRACKELJAN in [Str93] schon selbst erkannte, „kann die Aggregation der nichtzusammenhängenden Gebiete zu einer Gesamtklasse oder die Verfälschung der eigentlich konkaven Merkmalsstruktur durch die Transformation in eine konvexe Funktion zum Entwurf eines ungeeigneten Klassifikators oder schlimmer noch, zu einer Ablehnung einer potentiell geeigneten Merkmalskombination während der klassifikatorgebundenen Merkmalsauswahl führen“.




Abbildung 4.1: a) Merkmalskombination mit disjunkter semantischer Klasse  $\Omega_1$ , b) Merkmalskombination mit konkaver Clusterstruktur

Durch die klassifikatorbezogene Merkmalsauswahl – unter Berücksichtigung der in Abschnitt 4.1 vorgestellten Güterwerte – ist zwar sichergestellt, daß diejenigen Merkmalskombinationen, die in ihrer Struktur von der hyperelliptischen Form abweichen, eliminiert werden, jedoch sind die so ausgewählten Kombinationsmöglichkeiten keinesfalls die leistungsfähigsten Varianten. Selbst bei der Berücksichtigung aller möglichen Merkmalskombinationen stellen die ausgewählten Varianten nicht die für die klassifikatorimmanente Clusterstruktur optimalen Lösungen dar. D. h. es werden lediglich die Merkmalskombinationen ausgewählt, die – unter Berücksichtigung der vom Lehrer vorgegebenen semantischen Klasseneinteilung – den geringsten Klassifikationsfehler aufweisen.

Betrachtet man beispielsweise das XOR-Problem in Abbildung 4.1 a) wird deutlich, daß sämtliche Cluster vollständig disjunkt sind. Die Vorgabe der angegebenen semantischen Klassen  $\Omega_1$  und  $\Omega_2$  ergibt jedoch nicht disjunkte Zugehörigkeitsfunktionen. Der Klassifikator ordnet zwar alle Elemente der Klasse  $\Omega_1$  bei der Reklassierung korrekt zu, aber bei der Klasse  $\Omega_2$  werden 14 Merkmalsvektoren falsch klassifiziert. Diese Tatsache drückt sich in einer sehr geringen Reklassierungsgüte von nur 86 % aus. Diese Merkmalskombination, die zumindest als komplette semantische Klasse  $\Omega_1$  in ihrer Struktur von der im Klassifikator definierten elliptischen Form abweicht, wird also durch den schlechten Güterwert vom Auswahlalgorithmus (Abschnitt 4.2) eliminiert. Da die einzelnen disjunkten Cluster jeder für sich jedoch der elliptischen Form genügen, ergibt

eine der Clusterstruktur angepaßte Aufteilung der semantischen Klasse  $\Omega_1$  in zwei Subklassen  $\Omega_{11}$  und  $\Omega_{12}$  eine optimale Reklassierungsrate von 100% (Abbildung 4.2).




Abbildung 4.2: a) (Sub-)Clusterstruktur nach der Überführung des Zwei-Klassen-Problems aus Abbildung 4.1 a) in ein an die Clusterstruktur angepaßtes Drei-Klassen-Problem, b) Zugehörigkeitsfunktionen der Klassen  $\Omega_{11}$ ,  $\Omega_{12}$ ,  $\Omega_2$

Die Ausführungen zur XOR-Problematik lassen eindeutig erkennen, daß die der Lernmenge immanente semantische Klassenstruktur das Auffinden von geeigneten Merkmalskombinationen erheblich erschwert, wenn sie von der idealen hyperelliptischen Form abweicht. Die sich daraus ableitbare theoretische Fragestellung – mit der sich Kapitel 5 beschäftigt – lautet somit:

Ist es möglich – und wenn ja, mit welchem Algorithmus – aus der der Lernmenge immanenten Clusterstruktur weitere Subklassen der vorgegebenen semantischen Klassen mittels einer divisiven hierarchischen Clusterung zu gewinnen, die zu einer Verbesserung der Klassifikationsergebnisse mit dem in Kapitel 3 vorgestellten Fuzzy-Prototyp-Klassifikator führen?





## 5 Divisive hierarchische Clusterung mittels Wasserscheiden-Transformation (DHCL<sub>WST</sub>)

Die in der Mustererkennung und Datenanalyse verwendeten Clusterverfahren lassen sich nach [Zim91] in graphentheoretische Ansätze, Verfahren mit Zielfunktionen und hierarchische Methoden einteilen. Allen Clusteralgorithmen ist jedoch gemein, daß sie Objekte zu Klassen zusammenfassen. Dabei kann jedes Objekt im Rahmen einer unscharfen Formulierung eine Zugehörigkeit zu jeder der jeweiligen Klassen aufweisen.

Die hierarchischen Methoden erzeugen eine Rangfolge möglicher Klasseneinteilungen. Nach [Zim93] werden zwei mögliche Vorgehensweisen unterschieden:

- Jedes Objekt repräsentiert eine Klasse. Es werden nun sukzessiv Klassen miteinander verschmolzen, bis die gewünschten Klassen vorliegen. Dieses Verfahren wird agglomerative hierarchische Clusterung genannt.
- Alle Objekte gehören einer Klasse an. Sukzessiv werden nun neue (Sub-)Klassen erzeugt, die zu einer „sinnvolleren“ Klassenbildung führen. Bei diesem Vorgehen, das divisive hierarchische Clusterung heißt [Dum88], werden also bestehende Klassen in neue Klassen geteilt.

In diesem Abschnitt wird nun ein neues divisives hierarchisches Clusterverfahren innerhalb eines Mustererkennungssystems zur Schwingungsüberwachung vorgestellt, bei dem eine Klasse ebenfalls durch mehrere getrennte Cluster gegeben sein darf, die mittels der aus der digitalen Bildverarbeitung stammenden Wasserscheiden-Transformation (WST) ermittelt werden. Im Gegensatz zu anderen Clusterverfahren wie zum Beispiel:

- Fuzzy-c-Means (FCM),
- Learning Vector Quantization (LVQ) und
- Fuzzy Maximum Likelihood Estimation (FMLE)

soll der im folgenden beschriebene divisive hierarchische Clusteralgorithmus aber

- weder rechenaufwendige Iterationsverfahren verwenden,
- noch eine Abhängigkeit der Reihenfolge der Merkmalsvektoren bei der divisiven Clusterung aufweisen und
- von jeglicher Art an a priori Parametereingaben unabhängig sein.

Da die in Abschnitt 4 beschriebene beschränkt optimale Merkmalsauswahl bei hochdimensionalen Suchräumen durch die immens hohe Anzahl an Merkmalskombinationen sehr viel Rechenleistung in Anspruch nimmt, wird in diesem Abschnitt ein Clusterverfahren

ren entwickelt, daß auf klassische Iterationsverfahren verzichtet. Einige Verfahren, z. B. der in [Bun95] vorgestellte Algorithmus zur Variation der Klasseneinteilung, erzeugen zudem Ergebnisse, die von der Verarbeitungsreihenfolge der Stichproben abhängen. Dieser unerwünschte Effekt muß im Anschluß an die Clusterung durch weitere Rechenschritte beseitigt werden, was wiederum die Performance des Mustererkennungssystems negativ beeinflusst. Aber gerade der letzte Punkt stellt eine nicht zu unterschätzende Forderung an den Algorithmus dar, den viele Verfahren nicht erfüllen können. So erfordert beispielsweise die Parzen-Window-Methode (PWM) [Par62], [Dev82], bei der um jeden Merkmalsvektor der Lernmenge eine sogenannte Fensterfunktion gelegt wird, die Wahl einer geeigneten Fensterbreite. Da die Clusterverteilung im Merkmalsraum jedoch a priori unbekannt ist, ist es dem Anwender nahezu unmöglich eine der jeweiligen Problemstellung angepaßte Parametervorgabe einzugeben. Als Fazit bedarf es einer Vielzahl von empirischen Tests bis ein befriedigendes Ergebnis gefunden ist. Als weiteres Beispiel für diese Problematik können die LVQ-Verfahren [Koh90] genannt werden. Sie passen in einem iterativen Lernprozeß die Position der zuvor in Anzahl und Lage vom Benutzer vordefinierten Prototypen an die Klassenstruktur an. Besonders die zu initialisierenden Startpositionen der Prototypen haben oft einen deutlichen Einfluß auf das Ergebnis. Abschließend sei in diesem Zusammenhang noch auf den von BEHR [Beh97] vorgeschlagenen unscharfen Klassifikator mit lokaler Substruktur hingewiesen, der die Bestimmung der Parameter einer Summe aus Zugehörigkeitsfunktionen nach Gleichung (3.25) anhand lokal begrenzter Teilmengen der Lernmenge vorschlägt. Die Wahl der  $N$ -nächsten Nachbarn ohne Kenntnisse der Clusterverteilung kann jedoch auch hier einen erheblichen Einfluß auf die Güte des endgültigen Klassifikationsergebnisses haben.

Die Ansätze, auf die sich der divisive hierarchische Clusteralgorithmus stützt, lehnen sich dagegen an die von [Bun95] und [Ott98] formulierten Grundideen an:

- Die Anzahl der semantischen Klassen ist bekannt. Nicht bekannt ist allerdings, aus wie vielen Clustern eine Klasse besteht.
- Die für die Klassifikation geeignete Clusterstruktur muß aus der Strukturierung der Lernmenge im Merkmalsraum ableitbar sein und gleichzeitig in einer eindeutigen Beziehung zur semantischen a priori Klasseneinteilung durch den Lehrer stehen.
- Es wird erwartet, daß bei geeigneten Merkmalskombinationen die Cluster verschiedener Klassen einen möglichst großen Interklassenabstand aufweisen.

Im Gegensatz zu OTTE [Ott98], ist der Autor allerdings der Meinung, daß beim sogenannten „Überwachten Lernen“ – die Klassenzugehörigkeit der Lernmengenstichproben ist bekannt – der Algorithmus auf die nach Klassen getrennte Stichprobenmenge anzuwenden ist. Dieses Vorgehen hat den unverkennbaren Vorteil, daß bereits bei der Bildung der Subcluster die Klasseninformationen berücksichtigt werden, da das divisive

hierarchische Clusterverfahren immer nur Merkmalsvektoren einer semantischen Klasse zur Verarbeitung erhält. Das von OTTE angeführte Argument einer notwendigen a priori Festlegung der Clusteranzahl, in die jede Klasse zu partitionieren ist, ist hinfällig, da bereits in dem von BUNK [Bun95] drei Jahre zuvor vorgestellten iterativen „Algorithmus zur Clusterformation für die Variation der Klasseneinteilung“ eine solche vom Anwender anzugebende Parametervorgabe nicht mehr notwendig war. Der dort vorgestellte Clusteralgorithmus hat allerdings den Nachteil, daß das Klassifikationsergebnis von der Verarbeitungsreihenfolge der Merkmalsvektoren innerhalb des Iterationsverfahrens abhängt, was wiederum den oben beschriebenen Nachteil weitere Rechenschritte nach sich zieht.

Da der im Rahmen dieser Arbeit gewählte Fuzzy-Prototyp-Klassifikator aus Abschnitt 3 zur Berechnung der Zugehörigkeitsfunktionen Klassenprototypen mit zugehörigen Stichprobenverteilungen benötigt, sollte der Clusteralgorithmus die Clusterung ausgehend von den Clusterprototypen beginnen und die jeweiligen Merkmalsvektoren einer semantischen Klasse anschließend diesen Prototypen zuordnen können.

Um dies zu erreichen, wird um jeden Merkmalsvektor einer semantischen Klasse  $\Omega_k$  eine Kernelfunktion nach dem Vorbild der unimodalen parametrischen Zugehörigkeitsfunktion (3.25), die in Anlehnung an die Physik der Potentiale und konservativen Vektorfelder und zur begrifflichen Veranschaulichung im folgenden als Potentialfunktion bezeichnet wird, wie folgt festgelegt:

$$\Phi_{ks} = \frac{1}{1 + \frac{1}{t \cdot \mathbf{k}_k} (\mathbf{x} - \mathbf{m}_{ks})^2} \quad \text{mit } k = 1, \dots, K, \quad s = 1, \dots, S_k, \quad t, \mathbf{k}_k > 0. \quad (5.1)$$

Sie dient ähnlich wie die Fensterfunktionen der PWM zur Definition einer klassenbedingten (Wahrscheinlichkeits-)Dichte, oder um in der Begriffswelt der Physik zu bleiben, zur Beschreibung einer Ladungsverteilung im  $R^N$ . Durch die Wahl dieses Funktionstyps wird die Umgebung jedes Merkmalsvektors im Sinne einer unscharfen Formulierung in die anschließenden Berechnungen mit einbezogen. In Gebieten, in denen die Merkmalsvektoren eng benachbart sind, z. B. in der Nähe von Clustern, überlagern sich die Potentialfunktionen so, daß deren Summe, das Gesamtpotential

$$\Phi_k = \sum_{s=1}^{S_k} \Phi_{ks} \quad \text{mit } k = 1, \dots, K \quad \text{und } s = 1, \dots, S_k, \quad (5.2)$$

die unbekannte Verteilungsdichte der Merkmalsvektoren im Merkmalsraum  $R^N$  widerspiegelt (Abbildung 5.1).




Abbildung 5.1: a) Gesamtpotential der semantischen Klasse  $\Omega_1$ , b) Gesamtpotential der semantischen Klasse  $\Omega_2$

Die (relativen) Maxima des Gesamtpotentials können dann als sehr gute Näherung für die Clusterprototypen eventuell vorhandener Subcluster der semantischen Klasse  $\Omega_k$  angenommen werden. Ein Vorteil dieser Vorgehensweise gegenüber anderen Clusterverfahren ist, daß jeder einzelne Merkmalsvektor im Sinne einer unscharfen Logik an der Prototypenbildung eines jeden Clusters gleichberechtigt beteiligt ist, und erst durch die anschließende Zuordnung der Merkmalsvektoren zu den implizit vorliegenden Clusterprototypen mittels WST eine scharfe Klasseneinteilung vorgenommen wird. Dies ist sinnvoll, da das Mustererkennungssystem zur Parameterbestimmung der in Abschnitt 3 vorgestellten unscharfen Zugehörigkeitsfunktion eine scharfe Klassenzuordnung benötigt. Ein weiterer bedeutender Vorteil besteht darin, daß die Clusterprototypen unmittelbar durch das Gesamtpotential in ihrer Lage festgelegt sind, ohne daß iterative Berechnungsverfahren durchlaufen werden müssen.

Die einzigen Parameter zur Aufstellung der im Vorfeld zu bestimmenden Potentialfunktion (5.1) sind die Faktoren  $t$  und  $k_k$ . Sie legen in gewisser Weise die „Breite“ der Potentialfunktion fest. In [Rau93] wird zur Berechnung der Fensterbreite innerhalb der PW-Methode die Heuristik

$$\left( \frac{b}{100} \right) d_{k \max}^e \quad (5.3)$$

vorgeschlagen, wobei

$$d_{k \max}^e = \max_k \left( \sqrt{(\mathbf{m}_i - \mathbf{m}_j)^T (\mathbf{m}_i - \mathbf{m}_j)} \right) ; \quad k = 1, \dots, K \quad (5.4)$$

$$i, j = 1, \dots, S_k$$

ist und  $b$  in % vom Benutzer vorgegeben werden muß. Besitzt eine semantische Klasse jedoch getrennte, weit auseinander liegende Cluster – was der Benutzer in der Regel nicht weiß –, muß er unrealistisch hohe Werte von  $d_{k\max}$  durch ein sehr kleines  $b$  kompensieren. Dies kann er jedoch häufig erst durch eine Vielzahl intensiver Tests herausfinden.

Um dieser Problematik der Benutzeingabe zu entgehen, müssen die benötigten Parameter  $t$  und  $\mathbf{k}_k$  zur Festlegung der Funktionsbreite automatisch aus der Clusterstruktur abgeleitet werden. Der Parameter  $t$  bestimmt als multiplikativer Faktor die Lage des Wendepunktes der Potentialfunktion als Vielfaches von  $\mathbf{k}_k$ . Für die Untersuchungen in dieser Arbeit, und wie bereits in [Str93] für Gleichung (3.25) vorgeschlagen, wird auch hier der Parameter  $t = 3$  gesetzt, weil damit die Wendepunktskoordinate der Potentialfunktion mit der Wurzel der noch zu bestimmenden Größe  $\mathbf{k}_k$  zusammenfällt. Der noch freie Parameter  $\mathbf{k}_k$  sollte in Anlehnung an (3.20) ein Maß für die lokale statistische Verteilungsdichte der Merkmalsvektoren um einen Clusterprototypen darstellen. Da jedoch zu diesem Zeitpunkt noch keine Zuordnung der Merkmalsvektoren zu einzelnen implizit vorliegenden Prototypen erfolgen kann, ist die Berechnung der Varianzen einer Stichprobenkovarianzmatrix nicht möglich. Zur Berechnung des Parameters  $\mathbf{k}_k$  wird daher, ähnlich wie bei der PWM, mit euklidischen Abständen zwischen Merkmalsvektoren gearbeitet. Das mit (3.13) eingeführte gewichtete Distanzmaß steht zu diesem Zeitpunkt aus Ermangelung einer clusterbezogenen Stichprobenkovarianzmatrix noch nicht zur Verfügung.

Aus einer zufälligen Auswahl von  $Z_k$  Merkmalsvektoren  $\mathbf{m}_{ki}$  der gerade betrachteten semantischen Klasse  $\Omega_k$  werden alle

$$V_{kz}^2 = \binom{Z_k}{2} = \frac{Z_k!}{2!(Z_k - 2)!} \quad \text{mit} \quad Z_k \leq S_k \quad (5.5)$$

möglichen euklidischen Abstände

$$d_{kv}^e = \sqrt{(\mathbf{m}_{ki} - \mathbf{m}_{kj})^T (\mathbf{m}_{ki} - \mathbf{m}_{kj})} \quad \text{mit} \quad i \neq j, \quad i, j = 1, \dots, Z_k \leq S_k, \\ k = 1, \dots, K, \\ v = 1, \dots, V_{kz}^2 \quad (5.6)$$

zwischen den einzelnen Merkmalsvektoren berechnet. Um nun die lokalen Eigenschaften der Clusterstruktur gegenüber dem globalen Aufbau der Klasse  $\Omega_k$  hervorzuheben, und um eine Überbewertung von Abständen zwischen Merkmalsvektoren unterschiedlicher Cluster der selben semantischen Klasse  $\Omega_k$  zu vermeiden, werden die berechneten Abstände einer speziellen Mittelwertbildung unterzogen. Dazu müssen die  $V_{kz}^2$  Abstände

der Größe nach aufsteigend sortiert und anschließend nicht einer gleichgewichteten Mittelung sondern einer exponentiellen Mittelwertbildung mit

$$\overline{d}_k^e = \sum_{v=1}^{V_{kz}^2} \frac{(V_{kz}^2 - 1)^{v-1}}{(V_{kz}^2)^v} d_{kv}^e, \quad V_{kz}^2 \neq 0 \quad (5.7)$$

unterzogen werden. Bereits eine Stichprobenauswahl von bis zu 30% einer semantischen Klasse  $\Omega_k$  sind nach Erfahrungen des Autors dabei völlig ausreichend.

Die resultierende Potentialfunktion zur Berechnung des Gesamtpotentials nach (5.2) lautet somit

$$\Phi_{ks} = \frac{1}{1 + \frac{1}{3 \cdot d_k^e} (\mathbf{x} - \mathbf{m}_{ks})^2} \quad \text{mit } k = 1, \dots, K \text{ und } s = 1, \dots, S_k \quad (5.8)$$

Ist das Gesamtpotential bekannt, muß ausgehend von den relativen Maxima, die als Näherung für die unbekannten Clusterprototypen dienen, eine Zuordnung der Merkmalsvektoren erfolgen. Der Merkmalsraum wird also entsprechend der Verteilungsdichte der Merkmalsvektoren segmentiert, und die Merkmalsvektoren entsprechend ihrer Lage den ermittelten Segmenten (Subklassen) zugeordnet. Im Rahmen dieser Arbeit wird dazu ein Verfahren vorgeschlagen, das hauptsächlich in der medizinischen Bildverarbeitung von computer-tomographischen Aufnahmen eingesetzt wird und dort unter dem Begriff der Wasserscheiden-Transformation (WST) bekannt ist.

## 5.1 Segmentierung mittels Wasserscheiden-Transformation

Das grobe Ziel der (Bild-)Segmentierung ist, im Ergebnis(-bild) inhaltlich zusammengehörige Objekte als solche hervorzuheben. Nach [Leh97] kann man daher die Segmentierung wie folgt definieren:

Die Segmentierung dient zur hervorgehobenen Darstellung von inhaltlich zusammenhängenden Regionen durch Zusammenfassung benachbarter Bildpunkte, die einem bestimmten Homogenitätskriterium genügen.

Dabei reicht es i. a. nicht aus, Bereiche mit gleichen photometrischen Eigenschaften, beispielsweise dem Grauwert, zu suchen. Vielmehr müssen semantische Einheiten erkannt werden. Dazu werden im Bereich der Segmentierung zwei fundamentale Herangehensweisen unterschieden. Bei der Segmentierung aufgrund von Diskontinuitäten werden Bildbereiche gesucht, in denen sich die Intensität der Grauwerte lokal stark ändert. Bei einer Segmentierung nach Homogenitätskriterien werden Pixel gemäß eines

Homogenitätsprädikats zu maximal großen Regionen zusammengefügt. Die mit beiden Verfahren erzielten Ergebnisse sind äquivalent und können theoretisch ineinander überführt werden. Für die Verfahren der zweiten Kategorie sind ebenfalls drei prinzipielle Ansätze bekannt, die punkt-, die kanten- und die flächenorientierte Segmentierung.

- Punktorientierte Segmentierung:

Bei den punktorientierten Verfahren besteht die Idee darin, ein Homogenitätskriterium für Einzelpunkte zu definieren, das nur auf Grauwertbereiche fixiert ist. Es wird davon ausgegangen, daß verschiedene Objekte zueinander disjunkte Grauwertbereiche aufweisen. Die einfachsten dieser Verfahren zur Bildsegmentierung sind die sogenannten Schwellwertverfahren [Wah84].

- Kantenorientierte Segmentierung:

Bei den kantenbasierten Segmentierungsverfahren [Der87], [She92] wird versucht, die Grenzen zwischen Objekten zu finden. Dabei wird davon ausgegangen, daß zwischen zwei Objekten im Bild eine abrupte Grauwertänderung (Optische Kante) existiert. Ein Maß für die Änderung der Grauwerte findet man durch die erste partielle Ableitung des Bildes. Viele Kantenoperatoren berechnen daher die Kanten mit Hilfe des Gradienten. Ein Gradienten-Vektor zeigt immer in die Richtung des stärksten Grauwertanstieges und der Gradientenbetrag liefert ein gutes Maß für die Stärke der Kante. Kantenfilter besitzen unterschiedliche Eigenschaften bezüglich der Genauigkeit der Lokalisation, der Amplitude und der Bestimmung ihrer Richtung. Die resultierenden Konturen variieren in ihrer Geschlossenheit, Breite und Geradheit. Zu den wichtigen Qualitätskriterien zählen auch die Behandlung von Konturkreuzungen sowie das Rauschverhalten der Kantenfilter. Probleme treten bei diesen Verfahren meist dadurch auf, daß die extrahierten Merkmale nicht unbedingt geschlossene Konturen bilden. Konturfolgeverfahren, die anhand der Gradientenrichtung und des Gradientenbetrages das Schließen von unterbrochenen Kantenstücken erlauben, können jedoch nur bei der Überbrückung kleiner Lücken erfolgreich eingesetzt werden.

- Flächenorientierte Segmentierung:

Flächenwachstums-Verfahren benutzen Ähnlichkeiten zwischen benachbarten Bildpunkten, um ein zusammenhängendes Gebiet zu finden. Von einem Startpunkt ausgehend werden Merkmale mit den Nachbarn verglichen, um Punkte mit ähnlichen Eigenschaften zu finden. Untersuchungen zur Bildanalyse mit Hierarchischer Regionaggregation, Bereichswachstums- und Quadtree-Verfahren sind beispielsweise in [Xu94] beschrieben.

### 5.1.1 Wasserscheiden-Transformation

Die Wasserscheiden-Transformation (WST) ist eine Mischung aus den Methoden der kanten- und flächenorientierten Segmentierung. Eine ausführliche Beschreibung ist z. B. in [Har96] zu finden. Die Begriffe Wasserscheide und Staubecken sind dabei eigentlich aus dem Bereich der Geowissenschaften entliehen und sollen hier nur der Veranschaulichung dienen. Die Wasserscheiden-Transformation wird im Gegensatz zu den meisten flächenbasierten Segmentationsverfahren nicht auf dem ursprünglichen Grauwertbild, sondern auf dessen Gradientenbild ausgeführt.




Abbildung 5.2: Prinzip der Wasserscheidentransformation: a) Beginn der Flutung bei lokalen Minima, b) Errichtung der ersten Wasserscheide auf einem Plateau, c) Trennung aller Staubecken durch Wasserscheiden

Die Grundidee lässt sich leicht an Abbildung 5.2 erklären. Nimmt man den Betrag des Gradienten als Höhenwert, so muß man sich das Gradientenbild als dreidimensionales Relief vorstellen. Ausgehend von den lokalen Minima wird das gesamte Relief nun mit konstanter Geschwindigkeit geflutet. Um zu vermeiden, daß das ansteigende Wasser über den Rand eines Staubeckens fließt und sich mit den benachbarten Staubecken vermischt,



werden Dämme an der Stelle eines möglichen Zusammenflusses errichtet. Diese Dämme markieren die Wasserscheiden zwischen benachbarten Staubecken (vergl. Abbildung 5.2). Falls zwei Staubecken nicht durch einen Grat, sondern durch eine Hochebene voneinander getrennt sind, sorgt die Viskosität des Wassers für eine korrekte Markierung der Wasserscheide. Dies wird dadurch erreicht, daß die Hochebene durch mehrere Staubecken von verschiedenen Seiten her geflutet wird, und das Wasser sich mit konstanter Geschwindigkeit auf der Hochebene ausbreitet. Im WST-Algorithmus wird dies durch die schrittweise Bearbeitung der am Rand eines detektierten Staubeckens befindlichen Bildpunkte erreicht. Das Verfahren endet, wenn das Wasser seinen Maximalstand erreicht hat, und alle Wasserflächen durch Dämme getrennt sind.

Im Rahmen der vorliegenden Arbeit werden nun die einzelnen invertierten Gesamtpotentiale (Abbildung 5.3) der semantischen Klassen  $\Omega_k$  als Gradientenbilder im Sinne der digitalen Bildverarbeitung aufgefaßt und mit Hilfe der WST segmentiert. Im Anschluß an die WST können dann die Merkmalsvektoren aufgrund ihrer Lage innerhalb eines Segmentes (Staubeckens) zu Clustern zusammengefaßt werden, ohne daß während der Berechnung eine explizite Angabe von Clusterprototypen oder gar eine Abstandsberechnung innerhalb der Merkmalsebene erfolgen muß.




Abbildung 5.3: invertierte Gesamtpotentiale der semantischen Klassen  $\Omega_1$  und  $\Omega_2$  der XOR-Problematik

#### 5.1.1.1 Algorithmus der WST

Vor Beginn der Umsetzung der WST sind zunächst einige Anforderungen, die der Algorithmus erfüllen muß, festzulegen:

- Als a priori Information soll lediglich das „Bild“ des Gesamtpotentials – im Sinne eines „Gradientenbildes“ – dienen. Oftmals wird in der Literatur auf zusätzliche

Informationen zurückgegriffen, wie z. B. bei der markerbasierten WST in [Weg98], oder es werden zuvor geodätische Distanzen berechnet [Soi98].

- Weiterhin soll die WST gewährleisten, daß zwischen unterschiedlichen Staubecken geschlossene Wasserscheiden gezogen werden, und immer zuerst die Nachbarpunkte schon bekannter Ufer untersucht werden.

Das im ersten Punkt geforderte Input Image entsteht aus dem invertierten Gesamtpotential (Abbildung 5.3). Es wird in eine 8 Bit Graustufengraphik mit 10.000 Bildpunkten umgewandelt. Gleichzeitig wird ein Output Image erzeugt, das die fortlaufende Numerierung (Label) der gefunden Staubecken für jeden der Bildpunkte speichert.

---

**Algorithmus: WST**


---

**Gegeben:** Input Image mit dem Gesamtpotential als „Gradientenbild“

**Gesucht:** Output Image mit den Segmentbezeichnungen (Label)

- 1 Invertiere das Gesamtpotential und wandle es in eine 8 Bit Grauwertgraphik um
  - 2 Initialisiere das Output Image mit -1.
  - 3 Weise dem Rand des Input Image von der Breite eines Bildpunktes den Wert 0 zu.
  - 4 **Für** alle  $2^8$  Grauwerte **führe aus:**
    - 4.1 Flood-Methode.
    - 4.2 Label-Methode.
- 

Damit der WST-Algorithmus auch die zweite Anforderung erfüllen kann, wird ein Operatorfenster mit einer 8er-Nachbarschaft (Abbildung 5.4) verwendet. Für die Zuweisungsentscheidung eines Labels nach der WST-Logik aus Tabelle 5.1 wird der aktuelle Bildpunkt (Mittelpunkt des Operatorfensters) jedoch nicht herangezogen, weil das Operatorfenster immer nur einen bestimmten Bereich um den aktuellen Bildpunkt herum ausliest. Da mit dem verwendeten quadratischen Operatorfenster der Randbereich des Eingabebildes nicht betrachtet werden kann, wird zu Beginn der Berechnungen der Rand des Eingabebildes mit 0 initialisiert. Infolge dessen verkleinert sich das Eingabebild zwar minimal, das ist jedoch für das Ergebnis ohne Bedeutung.




Abbildung 5.4: Verschiebung des 8er-Nachbarschafts-Operatorfensters

Um dem aktuellen Bildpunkt ein Label zuzuweisen, untersucht man die Labelkombinationen der Nachbarbildpunkte. Zunächst werden alle Nachbarlabel in ein 1D-Array geschrieben und aufsteigend sortiert. Mittels der WST-Logik wird dann entschieden, ob dem aktuellen Bildpunkt eine Wasserscheide (Labelwert 0) oder die Nummer eines Staubeckens (Label  $> 0$ ) zugewiesen wird. Für diese Zuweisung eines Labels müssen zusätzliche Variablen initialisiert werden. Die eine Variable stellt die Anzahl der Labelsprünge im sortierten Array fest, während eine zweite Variable den letzten Arraywert zwischen speichert.

Tabelle 5.1: Entscheidungslogik der Wasserscheiden-Transformation

Fall	mögliche Labelkombinationen im Operatorfenster	Anzahl der Labelsprünge	Labelzuweisung nach der WST-Logik
1	-1 -1 -1 -1 -1 -1 -1	0	neues Label zuweisen
2	0 0 0 0 0 0 0	0	neues Label zuweisen
3	$L_i$ $L_i$ $L_i$ $L_i$ $L_i$ $L_i$ $L_i$	0	vorhandenes Label $L_i$ ( $> 0$ ) der Labelkombination übernehmen
4	-1 -1 -1 -1 0 0 0	1	neues Label zuweisen
5	-1 -1 -1 0 0 $L_i$ $L_i$	2	Label $L_i$ ( $> 0$ ) der Labelkombination übernehmen
6	-1 -1 -1 $L_i$ $L_i$ $L_i$ $L_i$	1	Label $L_i$ ( $> 0$ ) der Labelkombination übernehmen
7	-1 -1 -1 $L_i$ $L_i$ $L_i$ $L_i$	2	0 zuweisen
8	-1 -1 0 0 $L_i$ $L_i$ $L_i$	3	0 zuweisen
9	0 0 0 0 $L_i$ $L_i$ $L_i$	1	Label $L_i$ ( $> 0$ ) der Labelkombination übernehmen
10	0 0 0 $L_i$ $L_i$ $L_i$ $L_i$	2	0 zuweisen

Wird beispielsweise nur ein Labelsprung detektiert, so muß durch die WST-Logik entweder ein neues Label zugewiesen werden (Fall 4), oder auf Grund des Labels in der letzten Arrayposition dieses an den entsprechenden Bildpunkt im Output Image geschrieben werden (Fall 6, Fall 9). Zur Unterscheidung der Fälle 5 und 7 überprüft z. B. eine Boolean Variable, ob einer der Werte im sortierten Array den Wert 0 hat. Der Fall 8 repräsentiert alle weiteren Kombinationsmöglichkeiten, bei denen die Anzahl der Labelsprünge größer 2 wird. In Tabelle 5.1 sind sämtliche Kombinationsmöglichkeiten der acht Nachbarlabel des aktuellen Bildpunktes aufgelistet, die zur Umsetzung des Algorithmus notwendig sind.

Während der WST treten die Fälle 3 sowie 5 bis 10 nur in der sogenannten Flood-Methode auf. Mit ihr werden bereits gelabelte Bereiche erweitert. Durch die Analyse der Randbildpunkte eines Staubeckens erkennt die Flood-Methode auch homogene Grauwertbereiche (Plateaus).

---

**Algorithmus: Flood-Methode**


---

**Gegeben:** Input Image mit dem Gesamtpotential als „Gradientenbild“,  
aktueller Grauwert, höchstes vergebenes Label

**Gesucht:** Output Image mit den Segmentbezeichnungen (Label)

## 1 Wiederhole

1.1 **Für** alle Bildpunkte des Output Image, die  $>0$  sind, **führe aus:**

1.1.1 Schreibe alle Bildpunktpositionen im Operatorfenster, die im Output Image den Wert -1 und im Input Image den aktuellen Grauwert haben und nicht dem Mittelpunkt des Operatorfensters entsprechen in Array1

1.2 **Für** alle Einträge aus Array1 **führe aus:**

1.2.1 Schreibe die Nachbarwerte vom Output Image des aktuellen Eintrags in Array2

1.2.2 Sortiere Array2 aufsteigend

1.2.3 Führe für Array2 die WST-Logik aus

2 **Bis** 1.1.1 keine Positionen mehr findet bzw. das Array1 leer ist

---

Neue Labelwerte bzw Staubecken werden nur in der Label-Methode vergeben, deshalb treten dort nur die Fälle 1, 2 und 4 auf. Allerdings erfolgt dies immer erst nach der Erweiterung der vorhandenen Staubecken durch die Flood-Methode, wodurch eine Übersegmentierung durch die Label-Methode verhindert wird.

**Algorithmus:** Label-Methode

**Gegeben:** Input Image mit dem Gesamtpotential als „Gradientenbild“,  
aktueller Grauwert, höchstes vergebenes Label

**Gesucht:** Output Image mit den Segmentbezeichnungen (Label)

- 1 **Für** alle Bildpunkte, die im Input Image dem aktuellen Grauwert entsprechen und im Output Image den Wert -1 haben, **führe aus**:
  - 1.1 Schreibe alle im Operatorfenster befindlichen Werte des Output Image mit Ausnahme des aktuellen Bildpunktes (Mittelpunkt des Operatorfensters) in ein Array
  - 1.2 Sortiere dieses Array aufsteigend
  - 1.3 Führe für das Array die WST-Logik aus
  - 1.4 Schreibe die Nachbarwerte vom Output Image des aktuellen Eintrags in Array2
  - 1.5 Wenn neues Label zugewiesen wurde, rufe die Flood-Methode auf

## 5.2 Erzeugung WST-abhängiger Clusterstrukturen

Aus den Ergebnissen der Wasserscheiden-Transformation sind im letzten Berechnungsschritt die Clusterstrukturen für alle semantischen Klassen  $\Omega_k$  abzuleiten. Dazu müssen die Labelwerte aus dem Output Image der WST entsprechend den Koordinaten der Merkmalsvektoren im Merkmalsraum ausgelesen werden. Die ausgelesenen Labelwerte werden nun als zusätzliche Klasseninformation der Merkmalsvektoren aufgefaßt, die die Clusterstruktur der jeweiligen semantischen Klasse widerspiegeln. Die Labelwerte teilen somit jede semantische Klasse  $\Omega_k$  in Subklassen  $\Omega_{kl}$ . Mittels der so erweiterten Klassenbezeichnung werden jetzt durch den Klassifikator aus Kapitel 3 für jede Subklasse  $\Omega_{kl}$  die zugehörigen Clusterprototypen und Stichprobenvarianzmatrizen ermittelt.

**Algorithmus:** Clustering

**Gegeben:** Output Image der WST,  
Stichprobenmatrix

**Gesucht:** Stichprobenmatrix mit neuer Klassenstruktur

1 **Für** alle semantischen Klassen  $\Omega_k$  **führe aus:**

1.1 **Für** alle Merkmalsvektoren der Klasse  $\Omega_k$  **führe aus:**

1.1.1 Lies den Labelwert des Output Image entsprechend den Koordinaten des aktuellen Merkmalsvektors.

1.1.2 Ergänze die Klassenbezeichnung des Merkmalsvektors durch den ausgelesenen Labelwert

1.2 Sortiere die Stichprobenmatrix der semantischen Klasse  $\Omega_k$  entsprechend der neuen Klassenbezeichnung  $\Omega_{kl}$

2 Füge die Matrizen der semantischen Klassen zu einer Stichprobenmatrix zusammen

Auf Grund der Bildung von Subklassen und ihrer Verwendung zur Klassifikation wird jedoch eine weitere Operation notwendig. Als Ausgangsgrößen der Klassifikationseinheit wird nach wie vor die vom Anwender geforderte semantische Klasse  $\Omega_k$  verlangt. Der Klassifikator liefert jedoch mit

$$\hat{\mu}_s = \max(\mathbf{m}_k(\mathbf{m}_s)) \quad \text{mit} \quad k = 1, \dots, K, \\ l = 1, \dots, L_k \text{ und} \\ s = 1, \dots, S \quad (5.9)$$

die Zugehörigkeit des Merkmalsvektors zu einer der segmentierten Subklassen. Eine ergänzende Zuordnungstabelle muß somit die notwendige Beziehung zwischen den Subklassen, die der Clusterstruktur entsprechen, und der semantischen Klasseneinteilung liefern. Unter Anwendung der DHCL<sub>WST</sub> auf die XOR-Problematik aus Kapitel 4, Abbildung 4.1 a), und die konkave Klassenstruktur in Abbildung 4.1 b) ergeben sich Clusterstrukturen, die der Verteilungsdichte der Stichprobenvektoren im Merkmalsraum optimal angepaßt sind (Abbildung 5.5 a) und b)). Auf Grund der für den Klassifikator optimal angepaßten Aufteilung der semantischen Klasse  $\Omega_1$  in die Subklassen  $\Omega_{11}$  und  $\Omega_{12}$  (Abbildung 5.5 a) und c)) werden in beiden Fällen Reklassierungsraten von optimalen 100 % erreicht. Hingegen lagen die Reklassierungsgüten mit nicht segmentierten semantischen Klassen bei nur 86 % für das XOR-Problem und gerade einmal 77 % für die konkave Klassenstruktur.




Abbildung 5.5: Mittels  $\text{DHCL}_{\text{WST}}$  erzeugte Subklassenstrukturen, a) Subklassenstruktur der semantischen Klasse  $\Omega_1$  des XOR-Problems, b) Klasse  $\Omega_2$  des XOR-Problems, c) Subklassenstruktur der semantischen Klasse  $\Omega_1$  mit konkaver Clusterstruktur, d) Klasse  $\Omega_2$  des Problems mit konkaver Klassenstruktur,





## 6 Anwendungen

Zur Entwicklung und Erprobung der LabVIEW SubVI-Bibliothek mit dem erweiterten Fuzzy-Klassifikator wurden eine Fülle von Untersuchungen aus zum Teil völlig unterschiedlichen Bereichen der technischen Diagnostik experimentell durchgeführt. Eine kleine Auswahl von Anwendungsbeispielen soll die vielfältigen Einsatzmöglichkeiten der SubVI-Programmbibliothek zur Lösung von Klassifikationsaufgaben demonstrieren. Der Forderung nach verstärkter interdisziplinärer Forschung soll im folgenden durch die Vorstellung von Anwendungen, die nicht nur im klassischen Maschinenbau anzusiedeln sind, Rechnung getragen werden.

### 6.1 Subgingivale Konkrementerkennung zur Parodontitisvorsorge

Für Menschen ab dem 35. Lebensjahr sind Erkrankungen des marginalen Parodont nach der Karies die häufigste Ursache für Zahnverlust (Abbildung 6.1.1). Fast 80% aller über 40-jährigen Deutschen sind mittlerweile betroffen. Rechtzeitige Prophylaxe, ätiotrope Therapie und Nachsorge dieser Erkrankungen haben daher eine große Bedeutung für den Erhalt gesunder Zähne und schaffen die Voraussetzung für die Zahngesundheit der Bevölkerung. Ihre Sensibilisierung für eine angemessene und wirksame Zahnpflege schon im Kindesalter wird die ständig wachsenden Ausgaben im Gesundheitswesen auf dem Gebiet der Zahnbehandlungen und des vorzeitigen Zahnersatzes wesentlich eindämmen und ist deshalb von großem volkswirtschaftlichen Nutzen.




Abbildung 6.1.1: Erkrankungen des marginalen Parodont [Zah04]

Das menschliche Gebiß besteht aus den Zähnen und dem marginalen Parodont. Dieser wiederum aus den vier Geweben Gingiva, Desmodont, Cementum und Alveolarknochen. Er hat die Aufgabe, die Zähne im Mandibula bzw. Maxilla sicher zu verankern, mechanische Belastungen z. B. während des Kauvorganges aufzufangen und die Infil-

tration von Krankheitserregern entlang der Zahnoberfläche in das Körperinnere zu verhindern.

### 6.1.1 Entstehung und Ursachen einer Parodontitis

Voraussetzung für die Entstehung entzündlicher Erkrankungen des marginalen Parodont ist bakterieller Plaque auf den Zähnen. Ätiologisch handelt es sich also um eine Infektionskrankheit, in deren Verlauf sich zunächst oberhalb des Zahnfleischsaumes auf den Zähnen bakterieller Plaque ansammelt. Ohne adäquate Mundhygiene führt dieser Zahnbelag zu einer reversiblen Gingivitis (Abbildung 6.1.1 b)). Sie bietet Bakterien die Gelegenheit unter der Gingiva auf der Zahnwurzeloberfläche einen für die häusliche Mundhygiene kaum zu erreichenden Bakterienbelag zu bilden. In Zeiten geschwächter Immunabwehr kommt es dann zur Ausbildung und fortschreitender Vertiefung der befallenen Zahnfleischtaschen, einhergehend mit dem Abbau von Alveolarknochen, so daß ein Teil des marginalen Parodont irreversibel verloren geht –man spricht von einer marginalen Parodontitis. Die Immunabwehr kann bei dieser Erkrankung entweder durch genetische Faktoren und/oder Allgemeinerkrankungen (z. B. Diabetes) beeinträchtigt sein, sie kann aber auch – und das ist wissenschaftlich unstrittig – durch das Rauchen erheblich geschwächt sein. Insbesondere im Bereich des marginalen Parodont muß daher das Rauchen als einer der Hauptrisikofaktoren für die Entstehung und das Fortschreiten einer marginalen Parodontitis angesehen werden.

### 6.1.2 Anzeichen einer marginalen Parodontitis

Ein gesundes Zahnfleisch ist straff, blaßrosa und blutet beim Zähneputzen oder der Anwendung von Zahnseide nicht. Eine Schwellung und eine gerötete bis bläuliche Färbung des Zahnfleisches sowie das Bluten beim Zähneputzen (Abbildung 6.1.2) im Rahmen der täglichen Mund- und Zahnhygiene sowie nach dem Sondieren der Zahnfleischtaschen bei einer Zahnbehandlung sind u. a. ein sicheres Zeichen für das Vorliegen einer Zahnbitterkrankung.



Abbildung 6.1.2: Bluten nach dem Sondieren der Zahnfleischtaschen ist ein sicheres Zeichen für das Vorliegen einer Entzündung [Zah04]

Als Warnsignal muß daher bereits das häufiger auftretende leichte Bluten des Zahnfleisches beim Zähneputzen betrachtet werden. Das kann jedoch bei Rauchern aufgrund der gefäßverengenden Wirkung der Tabakbestandteile auch bei fortgeschrittenen Erkrankungen minimal sein. Auftretende Schmerzen, starkes Zahnfleischbluten, Zahnlockerung oder -wanderungen oder sowie Abszesse im Zusammenhang mit einer Parodontalerkrankung sind ernste Hinweise darauf, daß die Erhaltbarkeit des Zahnes bereits stark gefährdet ist.

### 6.1.3 Erkrankungsformen

Je nach Beginn und Verlauf werden verschiedene Formen der marginalen Parodontitis unterschieden.

Die im Kleinkindalter einsetzende sehr seltene präpubertäre Parodontitis beginnt bereits mit dem Durchbruch der Milchzähne.

Eine relativ seltene Form der Parodontitis stellt die um die Pubertät herum auftretende juvenile Parodontitis dar. In den meisten Fällen sind die mittleren Schneidezähne und ersten Molare von rasch fortschreitendem Knochenabbau betroffen. Das erfordert eine unverzügliche Behandlung, die aber häufig gar nicht oder zu spät vorgenommen wird, weil diese seltene Form der Erkrankung entweder übersehen oder zu spät erkannt wird. Die Ursache der juvenilen Parodontitis ist in den meisten Fällen ein erblicher Defekt körpereigener Abwehrzellen. Die Erkrankung tritt daher oft familiär gehäuft auf.

Zwischen der Pubertät und dem 35. Lebensjahr bedroht die rapid progressive Parodontitis das menschliche Gebiß, bisweilen als Folge einer nicht behandelten juvenilen Parodontitis. Die rapid progressive Parodontitis ist durch einen schnell fortschreitenden Knochenabbau gekennzeichnet, von dem sämtliche Zähne betroffen sein können. Nur bei einer rechtzeitig einsetzenden Behandlung und exzellenter Mundhygiene durch die Patienten kann ein weiteres Fortschreiten der Erkrankung verlangsamt oder günstigstenfalls aufgehalten werden. Wie bei der juvenilen Parodontitis spielen auch bei der rapid progressiven Form erbliche Defekte körpereigener Abwehrzellen eine entscheidende Rolle.

Die erst nach dem 35. Lebensjahr beginnende adulte Parodontitis (Abbildung 6.1.3) ist die häufigste Form der Parodontitis. Sie schreitet in den meisten Fällen nur langsam voran und befällt entweder nur einzelne oder alle Zähne. Eindeutige Warnsymptome fehlen zu Beginn der Erkrankung häufig, so daß infolgedessen oft erst nach Jahren diese Form der Parodontitis in einem leider schon fortgeschrittenen Krankheitsstadium erkannt wird. Dabei kann es bereits zu schweren Schädigungen am marginalen Parodont durch Zahnwanderungen und -lockerungen sowie zurückgegangener Gingiva kommen.

Durch eine angemessene Behandlung und optimale Mundhygiene läßt sich die adulte Parodontitis meist erfolgreich stoppen.




Abbildung 6.1.3: Typische Form einer Erwachsenen Parodontitis. Aufgrund der zahlreichen bakteriellen Beläge a) ist ein Abbau des marginalen Parodonts erfolgt [Zah04]

Wenn trotz optimaler Mundhygiene des Patienten und einer konsequent durchgeführten Behandlung der Abbau des Zahnhalteapparates fortschreitet, spricht man von einer refraktären Parodontitis. Von dieser seltenen Form der Erkrankung sind meist Raucher betroffen.

Darüber hinaus können anatomische, funktionelle und allgemeine Besonderheiten und Allgemeinerkrankungen des Patienten, wie z. B. Down-Syndrom, juveniler Diabetes mellitus und AIDS, den Verlauf und die Schwere des Krankheitsbildes wesentlich beeinflussen. Klinische Beobachtungen deuten eindeutig auf zusätzlich auslösende Faktoren wie Depressionen, Einsamkeit, Streß und Angst hin. Zudem haben neueste Erkenntnisse über die Übertragbarkeit der Krankheitserreger gezeigt, daß bei 30% aller untersuchten Partner innerhalb einer Familie bzw. Lebensgemeinschaft dieselben Keime nachgewiesen werden konnten, wie bei dem Erkrankten. Der Übertragung erfolgt über gemeinsam benutztes Eßgeschirr und Intimkontakt. Zwar ist noch nicht geklärt, ob es immer zu einer Übertragung der Erkrankung kommt, jedoch gehen Empfehlungen dahin, bei Patienten mit einer schweren, nicht durch mangelnde Mundhygiene bedingte Parodontitis den Partner in die Therapie mit einzubeziehen – auch dann, wenn dieser kein sichtbares Krankheitsbild aufweist.

#### 6.1.4 Phasen der systematischen Parodontaltherapie

Um einen anhaltenden Behandlungserfolg zu erreichen, ist insbesondere bei einer vorliegenden marginalen Parodontitis eine detaillierte, langfristig ausgerichtete Therapieplanung erforderlich. In diese Planung sind darüber hinaus auch zahnerhaltende und prothetische Aspekte mit einzubeziehen. Vor Beginn einer sogenannten systematischen Parodontalbehandlung ist deshalb eine umfangreiche Diagnostik unerlässlich, die

sich auf Röntgenbilder (Abbildung 6.1.4) und Situationsmodelle (Gipsmodelle von Ober- und Unterkiefer) sowie auch auf spezielle parodontologische Befunderhebung (Taschentiefen, Zahnlockerungen etc.) stützt.

Das Ziel einer Parodontalbehandlung muß in jedem Falle sein, ein weiteres Fortschreiten der Erkrankung langfristig zu verhindern. Allerdings wird sich in den wenigsten Fällen aufgrund einer konventionellen Zahnfleischbehandlung das marginale Parodont, das in der Vergangenheit abgebaut wurde, wieder regenerieren. Unter bestimmten Voraussetzungen und unter Anwendung moderner Methoden kann heutzutage allerdings versucht werden, einen Teil des verlorengegangenen Knochens und des Faserapparates wieder zurückzugewinnen. In den letzten Jahren haben Forschungsergebnisse mehr und mehr erkennen lassen, daß das Rauchen einer der drei Hauptfaktoren für das Fortschreiten einer Parodontitis ist. Aus diesem Grund wird sich die Raucherentwöhnung zu einem zentralen Bestandteil der Parodontalbehandlung entwickeln.



Abbildung 6.1.4: Orthopantomogramm eines Patienten mit einer weit fortgeschrittenen marginalen Parodontitis [Zah04]

Unter dem Begriff der systematischen Parodontaltherapie versteht man die Mundhygienephase, korrektive Phase und die Erhaltungsphase, wobei jeder dieser Phasen unterschiedliche Aufgaben zukommen.

#### 6.1.4.1 Mundhygienephase

Die Mundhygienephase – auch Initialphase genannt – soll die grundsätzlichen Voraussetzungen für einen langfristigen Erfolg der Behandlung schaffen. Besonderer Wert wird daher in dieser Phase auf eine optimale Mundhygiene gelegt, die auf die individuellen Verhältnisse des Patienten ausgerichtet ist und zu einer möglichst vollständigen Entfernung bakterieller Beläge vor allem in den Zahnzwischenräumen führen soll, da sich sonst kein längerfristiger Erfolg einstellen wird (Abbildung 6.1.5). Der Patient soll umfassend über die Ursachen seiner Erkrankung und die Bedingungen für einen Erfolg

versprechende Behandlung informiert werden, damit er entsprechend motiviert die Bemühungen des behandelnden Arztes unterstützt.




Abbildung 6.1.5: Reinigung der Zahnzwischenraumbegrenzenden durch Zahnseide [Zah04]

Es versteht sich von selbst, daß die Voraussetzungen für eine optimale häusliche Mundhygiene vorhanden sein oder aber durch das zahnärztliche Team geschaffen werden müssen. Wenn erforderlich, sind alte Füllungen und Kronen zu glätten oder sogar auszutauschen, um eine optimale Hygienefähigkeit für den Patienten zu erzielen. Eine bedarfsgerechte Zahnreinigung durch das Praxisteam, die mehrfach innerhalb einiger Wochen wiederholt werden muß, ist dabei obligatorisch.

Zum Abschluß der Mundhygienephase wird aufgrund eines ausführlichen parodontologischen Befundes entschieden, welche weiteren Behandlungsmaßnahmen durchzuführen sind. Ist im Einzelfall ein Patient jedoch nicht zu motivieren und deshalb nicht zu guter Mitarbeit bereit, macht eine weitergehende Parodontalbehandlung keinen Sinn, da unter diesen Umständen nicht mit einem Behandlungserfolg zu rechnen ist.

#### 6.1.4.2 Korrektive Phase

Ergibt sich im Anschluß an die Mundhygienephase weiterer Behandlungsbedarf, schließt sich die korrektive (chirurgische) Phase an. Sie verfolgt das Ziel, die Wurzeloberflächen von bakteriellen Belägen (dem sogenannten Biofilm) und subgingival befindlichen Konkrementen zu befreien. Dabei kommen grundsätzlich zwei unterschiedliche Verfahren in Betracht, deren Auswahl sich hauptsächlich nach der Tiefe der Zahnfleischtaschen und der Möglichkeit, den Biofilm zu erreichen, richtet.

In der korrektiven Phase werden als Behandlungsmethoden die geschlossene und die offene Kürettage angewandt. Bei der geschlossenen Kürettage (Abbildung 6.1.6 a)) wird auf das operative Freilegen der Wurzeloberfläche verzichtet. Stattdessen werden in der Regel nach örtlicher Betäubung Küretten und/oder Ultraschallscaler am Zahn entlang in die Zahnfleischtasche eingeführt, um die Wurzeloberfläche zu reinigen und zu glätten.




Abbildung 6.1.6: a) Bearbeitung der Wurzeloberfläche bei geschlossener Vorgehensweise: Kürette und/oder Ultraschallscaler werden in die Zahnfleischtasche eingeführt, b) Bearbeitung der Wurzeloberfläche bei offener Vorgehensweise: die Reinigung der Wurzeloberfläche erfolgt unter direkter Sicht [Zah04]

Ganz anders wird bei der offenen Kürettage – der sogenannten Lappenoperation – verfahren. Im Rahmen dieser Behandlungsmethode wird das Zahnfleisch nach lokaler Anästhesie und Skalpellchnitt vom Zahn und Knochen gelöst. Damit liegen die zu reinigenden Wurzeloberflächen frei und können unter direkter Sicht bearbeitet werden (Abbildung 6.1.6 b)). Ist die gründliche Reinigung abgeschlossen, wird das abgelöste Zahnfleisch wieder an Knochen und Zähnen angelegt und mit Nähten fixiert.

Welche von beiden Vorgehensweisen gewählt wird, hängt von einer Vielzahl an Faktoren ab. Ob die geschlossene oder offene Kürettage oder zuerst die geschlossene und bei Bedarf zu einem späteren Zeitpunkt die offene Vorgehensweise angewandt wird, läßt sich daher oft erst im Verlaufe einer Behandlung abschätzen. Jedenfalls wird der Zahnarzt nach Möglichkeit versuchen, mit dem geschlossenen Verfahren auszukommen. Zum einen ist es für den Patienten angenehmer und zum anderen wird ein weiteres Schrumpfen des Zahnfleisches vom Zahn weg auf ein Minimum reduziert. Ist ein entzündungsfreier Zustand mit der geschlossenen Kürettage allein nicht zu erzielen, läßt sich häufig das offene Verfahren allerdings nicht umgehen. Gleichwohl ist auch bei diesem Verfahren eine gute Mitarbeit des Patienten unabdingbare Voraussetzung für den erfolgreichen Einsatz.

#### 6.1.4.3 Erhaltungsphase (Recall)

Patienten, die einmal unter einer Erkrankung des Zahnhalteapparates gelitten haben, sind sehr anfällig für erneute Entzündungen in diesem Bereich. Folglich muß sich nach dem erfolgreichen Abschluß der korrektiven Behandlungsphase unbedingt die sogenannte Erhaltungsphase anschließen. In der Erhaltungsphase sind Zähne, Zahnfleisch und häuslichen Mundhygiene regelmäßig zu kontrollieren. Zu den Kontrollsitzen sollte zusätzlich eine gründliche Zahnreinigung vorgenommen werden. Werden dabei

Blutungen des Zahnfleisches (Abbildung 6.1.2) festgestellt, sind diese immer ein eindeutiges Zeichen für eine Entzündung, die gegebenenfalls eine erneute Reinigung der Wurzeloberflächen in dem betroffenen Bereich erforderlich machen.

Der Abstand zwischen den Kontrolluntersuchungen hängt von der Schwere der Erkrankung und der Mitarbeit des Patienten ab, jedoch sollte ein Zeitraum von 6 Monaten nicht überschritten werden. Im Normalfall ist ein vierteljährlicher Rhythmus ausreichend.

In der Praxis wird die Bedeutung der Erhaltungsphase von den Patienten häufig unterschätzt. Aber speziell diese Phase ist entscheidend für einen dauerhaften Erhalt der Zähne. Die regelmäßige Inanspruchnahme der Kontrollsitzen ist daher unerlässlich, da sonst oft innerhalb kurzer Zeit ein Wiederaufflammen und weiteres Fortschreiten der Erkrankung festzustellen ist, und damit die sehr umfangreiche und aufwendige Behandlung vergebens war.

### **6.1.5 Probleme bei der heutigen Parodontitisbehandlung**

Bis vor einigen Jahren wurden Behandlungen während der korrektiven Phase hauptsächlich als Lappenoperation durchgeführt. Heute verzichten viele Zahnärzte dank neuer Techniken immer öfter auf den Griff zum Skalpell. Mit Ultraschall und speziellen Instrumenten werden Biofilm und Konkrement aus den Zahnfleischtaschen mittels der geschlossenen Kürettage entfernt. Das Verfahren ist auch unter der Bezeichnung „Scalen“ bekannt. Das Scalen wird entweder mit Handinstrumenten oder mit Hilfe von elektrisch betriebenen Ultraschallscalern durchgeführt.

Bedingt durch die komplizierte Wurzelmorphologie und die infolgedessen schwierige und zeitraubende Oberflächenbearbeitung mit Handinstrumenten wurden Ultraschallgeräte entwickelt, die mit Schwingungen der Arbeitsspitze von 20 bis 40 kHz arbeiten. Schwingungsform und Amplitude variieren hierbei je nach verwendetem System und der Form der Arbeitsspitze. Bei Ultraschallscalern werden die harten, ausmineralisierten Konkreme und der weiche Biofilm mechanisch durch Kontakt der schwingenden Arbeitsspitze mit der Zahnoberfläche entfernt. Durch periodische Schwingbelastung des Konkremes und der Zahnoberfläche kommt es zu Mikrogleitungen im oberflächennahen Bereich, zu Rißbildung, Materialermüdung und letztendlich zum Bruch des Konkremes bzw. der Zahnoberfläche. Mit den herkömmlichen Instrumenten wird also neben Konkrement und Biofilm auch Zahnhartsubstanz abgetragen. Zwar wird beim Gebrauch von Küretten gelehrt, daß nur Zahnstein und nicht Zahnhartsubstanz entfernt werden soll, doch sind die meisten Behandler nicht in der Lage, nur selektiv Konkrement und nicht Zahnhartsubstanz abzutragen.

Unterhalb des Zahnfleisches – in den Zahnfleischtaschen – besteht zudem die Problematik, daß die taktile und visuelle Kontrolle stark eingeschränkt ist. Die bisher



verwendeten Instrumente sind nicht in der Lage, zwischen Zahnbelägen und der gesunden Zahnhartsubstanz zu unterscheiden, wodurch die Instrumentenspitze wahllos Zement oder Konkrement bearbeitet. Da die zu bearbeitende Wurzeloberfläche systematisch vom Behandler mit dem Ultraschallgerät überstrichen wird, um keinen Anteil unbearbeitet zu belassen, wird bei der geschlossenen Kürettage immer auch gesunde Zahnhartsubstanz mit abgetragen (Abbildung 6.1.7). Die heute erzielbaren Güten in der Behandlung sind wenig überzeugend. Aktuelle Studien [Koc97] zeigen, daß selbst erfahrene Zahnärzte nur eine Sicherheit von 50 bis 60 % bei der Entfernung der Konkremeente erreichen. Es wird mit den herkömmlichen Methoden also einerseits Konkrement unbehandelt zurückgelassen, andererseits kommt es zu einer Übertherapie, d. h. auf schon gereinigten Stellen wird gesunde Zahnhartsubstanz abgetragen. Diese aggressive Wurzeloberflächenbehandlung führt dann zu einer Freilegung der Dentintubuli und damit zur Zahnhalsüberempfindlichkeit. Diese Nebenwirkung hält manchen Patienten von der Parodontaltherapie ab.




Abbildung 6.1.7: rasterelektronenmikroskopische Aufnahme einer durch Übertherapie geschädigten Zahnoberfläche

### 6.1.6 Grundprinzip der automatisierten Oberflächenerkennung

Zur Lösung der o. g. Problematik entstand an der Abteilung für Parodontologie der Universität Greifswald und am Institut für Technische Mechanik der TU Clausthal die Idee, einen Ultraschallscaler zusätzlich mit einem „intelligenten“ Mustererkennungssystem zur automatischen Zahnoberflächen- und Konkrementerkennung auszustatten. Der erste prinzipielle Nachweis, daß das Schwingungsverhalten des Scalers durch die berührte Zahnoberfläche beeinflußt wird, wurde bereits in [Str93] erbracht.




Abbildung 6.1.8: a) Prinzipskizze eines Ultraschallscalers, b) System zur automatischen Zahnoberflächen- und Konkrementerkennung mittels Ultraschallscaler (Scalerschnittbild mit freundlicher Genehmigung der Firma Sirona Dental Systems, Bensheim)

Das entwickelte System zur automatischen Zahnoberflächenerkennung besteht hardwareseitig aus dem Ultraschallscaler, der sowohl als Actor als auch als Meßsensor verwendet wird (Abbildung 6.1.8 a)), dem Anregungssystem und dem Datenaufzeichnungs- und Datenanalysesystem.

Das Anregungssystem produziert eine Rechteckimpulsfolge mit einer Amplitude von circa 200 V und einer Impulsdauer von etwa  $10^{-5}$  s, die das Piesosystem des Scalers ungefähr 50mal in der Sekunde zu Schwingungen anregt, wobei die Amplituden an der Nadelspitze mit weniger als  $5\text{ }\mu\text{m}$  sehr gering ausfallen (Abbildung 6.1.8 b)). Die Oberflächenantwort auf die Impulsfolgenanregung induziert nun ebenfalls eine mechanische Deformation der Piezokeramik, was wiederum zu Spannungsänderungen an den Elektroden der Piezoelemente führt. Das Gesamtsignal aus Impulsanregung und Rückwirkung wird über einen Antialiasing-Filter mittels eines rechnergestützten Datenerfassungs- und Mustererkennungssystems gemessen und ausgewertet. Die Methode ähnelt im Grundprinzip dem Test von Gläsern oder Porzellan durch

Anschlagen mit dem Finger, bei dem sich Veränderungen oder Risse akustisch auch recht leicht bemerkbar machen.

Die klassischen Scaler ohne Erkennungsmöglichkeit verwenden an Stelle der Rechteckimpulsfolge zum Abtrag ein Sinussignal, das die Nadel zu einer kontinuierlichen Schwingung mit Amplituden von ca. 50 µm anregt und dabei die Konkremente entfernt. Immer wenn im Detektionsmodus durch die Rechteckfolge Konkremente erkannt werden, kann das System auf den normalen Leistungsbetrieb zur Entfernung umgeschaltet werden. Dies kann manuell durch den Behandler oder automatisch gesteuert durch das Dentalgerät erfolgen. Dieser Ultraschallschwinger ist ein schönes Beispiel eines mechatronischen Systems, bei dem neue Funktionalitäten erst durch die Kopplung von Mechanik, Elektronik und Signalverarbeitung entstehen.

Mittels einer geeigneten Merkmalerzeugung, die durch die Transformation des Zeitsignals in den Spektralbereich erfolgen kann, ist eine prinzipielle Unterscheidbarkeit von Zahnoberflächen möglich. Um Frequenzanteile auch oberhalb der 1. Eigenfrequenz des Scalers für die Klassifikation berücksichtigen zu können, werden das Ausgangssignal des Scalers mit einer Frequenz von 256 kHz abgetastet. Bei der Meßfensterlänge von 1024 Punkten ergibt sich eine Frequenzauflösung von

$$\Delta f = \frac{f_A}{N_F} = \frac{256.000 \text{ kHz}}{1024} = 250 \text{ Hz} . \quad (6.1.1)$$

Zur Wahrung eines ausreichenden Abstandes zur Nyquistfrequenz werden – wie allgemein üblich – von den 512 möglichen diskreten Frequenzlinien nur 400 im Amplitudenspektrum dargestellt und über fünf Einzelmessungen gemittelt. Folglich ergibt sich ein Merkmalsvektor mit 400 Merkmalen, der das Schwingungsverhalten des Scalers in Abhängigkeit zur berührten Oberfläche in einem Frequenzbereich von 0 bis 100 kHz beschreibt. Jeder der in diesem Fall 400 Magnitudenwerte kommt als potentiell Merkmal für den Entscheidungsprozeß, welche Oberfläche momentan berührt wird, in Betracht.

### 6.1.7 Ergebnisse der automatischen Konkrementeerkennung

Für die in dieser Arbeit verwendete Lernmenge wurden in Kooperation mit der Abteilung für Parodontologie der Universität Greifswald in-vitro-Versuche an insgesamt 18 extrahierten Zähnen durchgeführt. Die ein- und mehrwurzeligen Zähne, die nach der Extraktion in einer 5%igen Formalinlösung lagerten, wurden kurz vor Versuchsbeginn in ein zähelastisches Abdruckmaterial eingebettet. FEM-Rechnungen konnten zeigen, daß für das Schwingungsverhalten der Nadel die Nahfeldwirkung entscheidend ist. Der Einfluß der Lagerung kann daher weitestgehend vernachlässigt werden.




Abbildung 6.1.9: zwei Amplitudenspektren der Klassen (Lernmengen) „Wurzel“ und „Konkrement“ mit klassenzugehöriger Standardabweichung als y-Fehlerindikator.

Während einer Messung wird die Nadelspitze des Scalers für jeweils 3-5 Sekunden mit einer definierten Kraft von 0,45 N und dem üblichen Arbeitswinkel an die Wurzelsubstanz bzw. die subgingivalen Konkreme des Zahnes gehalten und weitestgehend nicht bewegt. In dieser Zeit erfolgt die Vermessung des oberflächenspezifischen Schwingungsmusters (Abbildung 6.1.9) und die Vergabe eines klassenspezifischen Labels durch den erfahrenen Experimentator. Insgesamt entstand so eine Lernmenge mit 104 Stichproben der semantischen Klasse „Wurzel“ und 97 Stichproben der semantischen Klasse „Konkrement“.

Die Analyse der Lernmenge zeigt nun, daß bei einigen charakteristischen Frequenzen Amplitudeabweichungen in Abhängigkeit der verschiedenen Zahnoberflächen auftreten, während große Frequenzbereiche nahezu identische Amplituden aufweisen. Dabei ist zu bemerken, daß dies allein die Klassifikationsaufgabe noch nicht löst, denn durch die großen Streuungen treten Überlagerungen der Clusterstruktur der beiden semantischen Klassen auf (Abbildung 6.1.10). Dennoch muß ein Klassifikationsalgorithmus für jeden der eingezeichneten Punkte eine Beurteilung vornehmen, ob es sich um Konkrement handelt oder nicht. Da die Übergänge zwischen beiden Klassen also nicht scharf abgegrenzt sind, empfiehlt sich gerade hier der Einsatz des Klassifikators aus Kapitel 3, der diesem Tatbestand Rechnung trägt. Allein durch die unscharfen Klassengrenzen ist es möglich, für jeden der eingezeichneten Punkte eine Beurteilung vorzunehmen.




Abbildung 6.1.10: Merkmalsebene mit Klassifikator der besten Zweierkombination ohne  $DHCL_{NST}$

Die Suche in der gesamten Suchbasis mit zwei Merkmalen mittels des Abstandsklassifikators (3.25) findet zwar keine Kombinationen, die eine 100%ige Trennung der semantischen Klassen „Wurzel“ ( $\Omega_1$ ) und „Konkrement“ ( $\Omega_2$ ) erlauben, allerdings werden immerhin 19 Kombinationen gefunden, die eine Reklassierungsgüte von über 0,85 bzw. 85 % erreichen

(Tabelle 6.1.1). Die beste dieser Kombinationen erreicht eine Zugehörigkeitsdifferenz von 0,398. Die beste Reklassierungsgüte liegt mit der Merkmalskombination 339 und 383 bei 88 %. Dies bedeutet, daß 24 der insgesamt 201 Stichproben nicht korrekt klassifiziert werden. Abbildung 6.1.10 zeigt deutlich, daß sich die Cluster der beiden semantischen Klassen für diese Merkmalskombination überlagern. Eine 100% Trennung der Klassen ist somit zumindest für diese Merkmalskombination unabhängig vom Klassifikator ausgeschlossen. Die Ausreißerpunkte der Klasse „Wurzel“ am linken unteren Rand der Merkmalsebene und die drei Punkte der Klasse „Konkrement“ im rechten oberen Bereich könnten allerdings auch ein Hinweis auf eine a priori falsche Klassenzuweisung bei der Lernmengengenerierung sein.

Tabelle 6.1.1: Bestenliste der Merkmalsauswahl im  $U^2$  ohne  $\text{DHCL}_{\text{WST}}$ 

Nr.	$G_R^2$	$\bar{G}_D$	Fehler	Merkmal 1	Merkmal 2
1	88,060	0,398	24	329	383
2	87,562	0,402	25	328	383
3	87,562	0,371	25	329	384
4	87,065	0,362	26	328	382
5	87,065	0,343	26	123	384
6	87,065	0,340	26	101	118
7	87,065	0,319	26	135	386
8	86,567	0,364	27	100	134
9	86,567	0,352	27	326	382
10	86,070	0,382	28	326	383

Die im Vergleich zu einem erfahrenen Zahnarzt schon sehr guten Klassifikationsergebnisse der Suchbasis mit 2 Merkmalen lassen vermuten, daß bei einer Anpassung der Klassenstruktur an die tatsächlich vorliegende Clusterstruktur mittels  $\text{DHCL}_{\text{WST}}$  der Abstandsklassifikators nach (3.25) in der Lage sein sollte, Zweierkombinationen mit einer Reklassierungsrate von über 90 % zu finden. Die Grundlage dafür bildet eine Bestenliste  $\hat{U}_0^2$  (Aufnahmebedingung:  $G_R^2 \geq 0,815$ ), für deren 496 Merkmalskombinationen die  $\text{DHCL}_{\text{WST}}$  durchgeführt wird. Als Ergebnis liefert diese Methode 30 Zweierkombinationen die eine über 90%ige Trennung erlauben. Mit einer Reklassierungsrate von ca. 94 % und einer mittleren Zugehörigkeitsdifferenz, als Maß für den Interklassenabstand, von  $\bar{G}_D \geq 0,405$  steht die Kombination mit den Merkmalen 100 und 134 auf dem ersten Platz der Bestenliste (Abbildung 6.1.11).

Tabelle 6.2: Bestenliste der Merkmalsauswahl im  $U^2$  mit  $\text{DHCL}_{\text{WST}}$ 

Nr.	$G_R^2$	$\bar{G}_D$	Merkmal 1	Merkmal 2	Listenposition ohne $\text{DHCL}_{\text{WST}}$
1	94,030	0,405	100	134	8
2	94,030	0,378	213	357	78
3	92,537	0,479	100	135	24
4	92,537	0,464	136	388	66
5	92,537	0,364	329	383	1




Abbildung 6.1.11: Ausschnitt zweier Amplitudenspektren von Stichprobenvektoren aus den Klassen "Wurzel" und "Konkrement" mit der klassenzugehörigen Standardabweichung als y-Fehlerindikator

In Abbildung 6.1.12 b) und d) ist sehr gut zu erkennen, daß durch die Segmentierung der Merkmalsebene die semantischen Klassen in mehrere Sub-Klassen aufgeteilt werden. Insbesondere die daraus resultierende Verbesserung der Klassenstruktur im oberen rechten Bereich der Merkmalsebene ist für die Steigerung der Reklassierungsrate um 6 % verantwortlich. Durch die DHCL<sub>WST</sub> werden von den 201 lediglich noch 12 Merkmalsvektoren falsch klassifiziert. Der Versuch einer weiteren Steigerung der Reklassierungsrate durch die Merkmalsauswahl auf Basis des vollständigen dreidimensionalen Unterraumes  $U_0^3$  ergab oberhalb eines Grenzwertes  $\tilde{G}_R^2 = 0,95$  keine weitere Ergebnisverbesserung. Eine Dimensionserhöhung des Suchraumes ist somit nicht generell einer divisiven hierarchischen Clustering zur Optimierung der Klassenstruktur vorzuziehen.

Abschließend bleibt somit festzustellen, daß die guten Ergebnisse der Experimente – mit Erkennungsraten von 95 % unter Laborbedingungen – neue diagnostische Behandlungsgeräte im Bereich der Parodontologie ermöglichen werden. Um die Erkennungsraten auch in praxi weiter zu verbessern, ist es unbedingt notwendig weitere in-vivo-Experimente durchzuführen, um z. B. die Streuungen durch

- veränderliche Umgebungsbedingungen und unterschiedliche Behandler,
- Fertigungstoleranzen und Abnutzungen der Nadeln

zu erfassen.




Abbildung 6.1.12: a) Merkmalsebene der Merkmale 100 und 134, b) und d) Merkmalsebene nach der DHCL\_WST und c) und e) Merkmalsebene mit den subclassespezifischen Zugehörigkeitsfunktionen



## 6.2 Akustische Güteprüfung von Mikrowellenbackröhren

Steigende Ansprüche seitens der Verbraucher in Bezug auf Qualität und Zuverlässigkeit nicht nur von Haushaltsprodukten, sowie ein zunehmender Konkurrenzdruck, zwingen die Hersteller von Komponenten und Endprodukten von Haushaltsgeräten zur Anwendung immer aufwendigerer Prüfverfahren in der Fertigungskontrolle.

Das betrifft in hohem Maße Produktionsfehler bei sicherheitsrelevanten und somit kritischen Komponenten, die durch Teil- und Komplettausfälle auch zu einer Gefährdung des Bedieners führen können. Bei Mikrowellenherden kann es beispielsweise durch Fehler an der Strahlungsquelle oder der Strahlungsabschirmung zu Strahlungslecks kommen, die eine erhöhte Strahlungsbelastung des Bedieners erzeugen. Aus diesem Grund wird jeder Mikrowellenherd einer aufwendigen Qualitätskontrolle zur Ortung von Strahlungslecks unterzogen, bevor er zur Auslieferung gelangt. Ziel dieser Qualitätskontrolle ist, Qualitätsbeanstandungen und eine Gefährdung des Endverbrauchers zu vermeiden. Mit dem Instrument der akustischen Güteprüfung verfügen die Prüffingenieure über ein vielseitiges, kostengünstiges und vor allem vor der Endfertigung durchzuführendes Alternativverfahren zur Detektion von Schäden an den Mikrowellenbackröhren, die zu Strahlungslecks führen können. Allein anhand des Klanges bzw. Körperschalls der Mikrowellenbackröhren ist eine Beurteilung des Zustandes möglich. Bei der Integration eines Prüfsystems in die Serienfertigung sind über die Funktionalität hinaus besondere Anforderungen zu erfüllen, deren Einhaltung von den speziellen Produktionsbedingungen abhängt. Am Beispiel der Detektion von Einschnürungen an Mikrowellenbackröhren wird gezeigt, wie die Anforderungen durch Einsatz des im Rahmen dieser Arbeit implementierten Mustererkennungssystems auf Basis einer LabVIEW SubVI-Bibliothek und unter Verwendung von akustischer Standardmeßtechnik erfüllt werden.

### 6.2.1 Erzeugung von Mikrowellenstrahlung

Mikrowellen sind elektromagnetische Strahlen im Frequenzbereich von 1 - 1000 GHz. In Mikrowellenherden werden diese Strahlen mittels eines Magnetrons (Abbildung 6.2.1) erzeugt. Im Magnetron werden aus der zylinderförmigen Kathode durch Glühemission Elektronen freigesetzt, die durch das mit der konstanten Spannung von ca. 4000 V verbundene elektrische Feld  $E_0$  zum Kupferanodenring beschleunigt werden. In dem Anodenring befinden sich in gleichmäßigen Winkelabständen kreisförmige Nuten, die eine entsprechende Anzahl an Schwingkreisen bilden. Um Frequenzen im Giga-Hertz-Bereich zu erhalten müssen die Werte der Kapazität und Induktivität der Schwingkreise entsprechend klein sein. Jede „Spule“ besteht daher nur aus einer einzigen Windung – gebildet durch die Nuten –, die offenen Enden bilden den Kondensator. Senkrecht zum elektrischen Gleichfeld zwischen Kathode und Anode wird mit einem Dauermagneten

ein konstantes Magnetfeld  $H_0$  erzeugt. Die Überlagerung der beiden Felder bewirkt eine komplexe Bewegung der Elektronen auf ihrem Weg von der Glühkathode zum Anodenring. Die Elektronen werden durch das magnetische Feld auf ihrem Weg zu den Schwingkreisen im Uhrzeigersinn abgelenkt. Elektronen, welche im elektrischen Wechselfeld eines Schwingkreiskondensators beschleunigt werden, kommen aufgrund der dadurch vergrößerten Lorentzkraft zur Glühkathode zurück. Dies ist in Abbildung 6.2.1 für ein Elektron in der Nähe des Schwingkreises 2 dargestellt. Elektronen, die im elektrischen Feld hingegen abgebremst werden und dadurch Energie verlieren (z. B. Schwingkreis 1) gelangen auf spiralförmigen Bahnen zur Anode (vergrößerter Ausschnitt in Abbildung 6.2.1), da die Lorentzkraft im Mittel entsprechend kleiner ist. Insgesamt wird dadurch erreicht, daß die von einer Glühkathode emittierten Elektronen bevorzugt dann in das elektrische Feld der Schwingkreiskondensatoren gelangen, wenn sie Energie an den Schwingkreis abgeben. Die Verstärkung des elektrischen Wechselfeldes der Schwingkreiskondensatoren geschieht durch Influenz. Die so erregte ungedämpfte elektromagnetische Schwingung induziert in einer in den Schwingkreis eingebrachten Auskoppelspule eine Induktionsspannung von üblicherweise 2,45 GHz. Über einen Wellenleiter gelangen die so erzeugten Mikrowellen in den Garraum.




Abbildung 6.2.1: Funktionsweise eines Magnetrons

### 6.2.2 Physiologische Wirkung und Grenzwerte hochfrequenter Mikrowellenstrahlung

Das elektromagnetische Feld schwingt 2,45-milliardenmal in der Sekunde; dies entspricht in Luft einer Wellenlänge von 12,25 Zentimetern. Dipolmoleküle, wie zum Beispiel Wasser, beginnen in einem solchen Wechselfeld ebenfalls zu schwingen. Durch diese Orientierungspolarisation erfolgt eine verstärkte Molekülbewegung, die direkt als Temperaturerhöhung meßbar ist. Da menschliches Gewebe zum weitaus größten Teil aus Wasser besteht, tritt auch hier eine Energieabsorption auf. Im Frequenzbereich  $> 100 \text{ kHz}$  ist für die physiologische Wirkung die Wärmewirkung entscheidend. Die Eindringtiefe in das Körpergewebe nimmt mit steigender Frequenz infolge zunehmender Energieabsorption im Körpergewebe ab (Abbildung 6.2.2).




Abbildung 6.2.2: Frequenzabhängigkeit der Eindringtiefe  $d$  für verschiedene Gewebe

Bei sehr hohen Frequenzen ( $> 10 \text{ GHz}$ ) wird schließlich die gesamte Leistung in den hautnahen Schichten absorbiert. Dabei kann auch die Augenlinse gefährdet sein, die sich wegen schlechter Kühlung und geringer Wärmekapazität leicht erwärmt. Innerhalb des Körpers können durch Reflexionen an Geweben unterschiedlicher Impedanz und Überlagerung mit der einlaufenden Welle und durch Fokussierungseffekte Bereiche mit höheren Leistungsdichten – sogenannte „Hot-Spots“ – entstehen, die sich dann stärker erwärmen als das umliegende Gewebe. Wegen der fehlenden Wärmerezeptoren im

Körperinnen ist die Überwärmung u. U. nicht oder verzögert wahrnehmbar. Hot-Spots findet man vorzugsweise im UHF-Bereich.

Die genormte Eindringtiefe  $d$  ist der Abstand zur Körperoberfläche bei dem die Strahlungsleistung auf circa 37 % ( $1/e$ ) des Wertes an der Oberfläche abgefallen ist. Um die Strahlungsleistung beispielsweise auf 5 % des ursprünglichen Wertes zu reduzieren, sind drei Eindringtiefen erforderlich.

Heutige Mikrowellenherde arbeiten mit einer Frequenz von 2,45 GHz und typischen Leistungen von 350 – 2200 Watt. Nach Untersuchungen des Bundesamtes für Strahlenschutz liegen die Leistungsdichte-Meßwerte für die Leckstrahlung an Haushalts-Mikrowellenherden – bis auf wenige Ausnahmen – unter  $10 \text{ W/m}^2$ . Die überwiegende Zahl der Geräte liegt unter  $4 \text{ W/m}^2$ . Der zulässige Emissionsgrenzwert beträgt nach DIN EN 60335-2-25 in 5 cm Abstand  $50 \text{ W/m}^2$ . Im Aufenthaltsbereich des Bedieners wird der Personenschutz-Grenzwert nach ICNIRP von  $10 \text{ W/m}^2$  jedoch nur bei Geräten mit eindeutigen Defekten, wie z. B. Rissen in den Mikrowellenbackröhren, undichte Türen und Türdichtungen, überschritten.

### 6.2.3 Bisheriges Konzept der Qualitätsprüfung

Risse in den Mikrowellenbackröhren können zu einem Strahlungsleck und damit zur völligen Unbrauchbarkeit des Herdes führen. Um die Auslieferung von Mikrowellenherden mit Strahlungslecks zu vermeiden, wird daher im Rahmen der Endkontrolle die gesamte Oberfläche des fertigen Herdes mit einer Antenne gescannt. Werden Strahlungslecks detektiert, wird der gesamte Herd als Elektroschrott entsorgt, da ein Auswechseln der defekten Backröhre weitaus höhere Personalkosten verursachen würde. Verantwortlich für die während des Emallierens entstehenden Risse sind sogenannte Einschnürungen, die beispielsweise durch verschlissene Werkzeuge während des Umformprozesses entstehen können. Eine Sichtprüfung durch Prüfpersonal nach dem Tiefziehen und verschweißen der Blechteile kommt jedoch aus Kostengesichtspunkten nicht in Betracht. Zudem stellt dieses Verfahren der subjektiven Prüfung hohe Anforderungen an die Konzentrationsfähigkeit der Prüfpersonen und die Ergebnisse sind stark von den individuellen Beurteilungsfähigkeiten der Prüfer abhängig. Darüber hinaus können anhand einer Sichtprüfung lediglich Fehler an der Oberfläche erkannt werden. Geringfügige Einschnürungen oder Risse im Innern des Materials sind optisch nicht ohne weiteres detektierbar, führen aber nach dem Emallieren der Backröhren ebenfalls zu offenen Rissen, die dann erst bei der Endkontrolle als Strahlungslecks entdeckt werden.

### 6.2.4 Untersuchungsmethoden und Grundlagen der akustischen Güteprüfung

Die akustische Güteprüfung stellt eine hervorragende Alternative zur visuellen Beurteilung von Objekten dar. Mit ihr lassen sich auch Fehler, die nicht an der Oberfläche zu erkennen sind, delektieren. Anhand des Klangs bzw. Körperschalls der Objekte ist eine Beurteilung des Zustandes möglich.

Mechanische Strukturen besitzen charakteristische dynamische Eigenschaften, die von der Form, dem Material und der Ankopplung an benachbarte Bauteile abhängig sind. Identische Objekte besitzen bei gleicher Ankopplung an Nachbarbauteile gleiche Eigenschaften, aber Abweichungen der Form oder Strukturveränderungen des Materials bewirken Änderungen der dynamischen Eigenschaften. Wird die Struktur angeregt, breiten sich im Material Wellen aus, die als Körperschall bezeichnet werden. Dabei sind in Festkörpern unterschiedliche Wellentypen (z. B. Longitudinal-, Transversal-, Biegewellen) möglich, die an Kanten, Grenzflächen und Materialinhomogenitäten durch Reflektionsvorgänge ineinander übergehen können. Das schwingende Gebilde regt an seiner Oberfläche Luftschall an, der sich allerdings nur als reine Longitudinalwelle ausbreitet. Die Analyse der Objekte kann somit anhand von Luft- oder Körperschallsignalen erfolgen. Im Gegensatz zu Luftschallsignalen sind dabei die Körperschallsignale weniger anfällig gegenüber Störeinflüssen durch abgestrahlten Luftschall der Produktionsumgebung.

Die dynamischen Eigenschaften von Strukturen werden mit Hilfe von Eigenfrequenzen, Dämpfungen und Eigenformen beschrieben. Dabei stellen die Eigenformen die Verteilung der Schwingungsamplituden auf der Strukturoberfläche dar. Zu ihrer Ermittlung und Beurteilung ist eine flächenhafte Messung der gesamten Strukturoberfläche oder zumindest charakteristischer Bereiche notwendig. Dies erfordert aber eine aufwendige Sensorik und Auswertung. Deswegen ist diese Methode für eine Serienprüfung nicht effizient. Dagegen können Resonanzfrequenzen, Dämpfungen und das lokale Schwingungsverhalten durch Auswahl geeigneter Meßpunkte an einzelnen Stellen bestimmt werden, wodurch die Prüfung zeit- und damit kostensparender wird.

Die zur Messung der dynamischen Eigenschaften notwendige Anregung der Prüflinge erfolgt bei der Materialprüfung extern, da häufig keine Eigenanregung möglich ist. Hierbei muß eine geeignete Lagerung gewählt werden, um die Dämpfungseigenschaften der Prüflinge, insbesondere im Bereich der Resonanzfrequenzen, nicht zu beeinflussen.

#### 6.2.4.1 Aufbau des Prüfstandes

Grundvoraussetzung für eine akustische Güteprüfung ist eine äußere Anregung des zu prüfenden Bauteiles. In diesem Zusammenhang ist unbedingt darauf zu achten, daß durch eine breitbandige Schwingungsanregung ein möglichst großer die signifikanten

Qualitätsmerkmale enthaltener Frequenzbereich erfaßt wird. Als Anregungsmechanismus kommen dazu

- Stoßimpulse,
- Gleitsinus und
- Rauschen

in Betracht, wobei die beiden Letztgenannten unbedingt berührungsfrei aufzubringen sind, um Rückwirkungen des Objektes auf den Schwingungserreger weitestgehend auszuschließen. Andernfalls ist eine Regelschleife zur Überwachung der Anregung zu verwenden.

Um einen möglichst großen Energieeintrag und eine berührungsfreie Anregung zu gewährleisten, wird die Backröhre über eine starke Schallquelle mit einem Rauschsignal im Frequenzbereich von 20 Hz bis 10 kHz beaufschlagt. Dadurch wird einerseits eine breitbandige Anregung mit konstanter Amplitude sichergestellt, andererseits können die Meßzeiten gegenüber einer Gleitsinusanregung sehr kurz gehalten werden.




Abbildung 6.2.3: Prinzipskizze der Prüfeinrichtung zur akustischen Güteprüfung von Mikrowellenbackröhren

Die Reaktion der Mikrowellenbackröhren auf die Schwingungsanregung führt nun im wesentlichen zu Querschwingungen der Röhrenoberflächen, welche sich je nach Schädigungsgrad von denjenigen des Gutzustandes unterscheiden sollten. Diese Schwingungen der Röhrenoberflächen werden punktuell auf der Oberseite mittels eines magnetisch applizierten piezoelektrischen Beschleunigungsaufnehmers registriert. Zum Einsatz kommen dabei sogenannte Miniaturaufnehmer, um Systemveränderungen durch angekoppelte Massen möglichst klein zu halten. Für einen späteren industriellen Einsatz

des Diagnosesystems können auch berührungslose Meßverfahren, wie z. B. Laserdopplervibrometer, eingesetzt werden, die zum einen eine rückwirkungsfreie Messung gestatten, und zum anderen Bedienfehler im Bereich der Aufnehmerankopplung vermeiden.

Wesentlicher Teil der Versuchseinrichtung ist das automatische, rechnergestützte Mustererkennungssystem, bestehend aus einer Kombination aus Analog/Digital-Wandler, Auswerterechner und Analyse- und Diagnoseprogrammen. Mittels des Analog-Digital-Wandler werden die vom Ladungsverstärker des Beschleunigungssensors ausgehenden analogen, tiefpaßgefilterten und schwingungsproportionalen Spannungssignale in zeit- und wertdiskrete digitale Signale überführt und der Softwareseite des Mustererkennungssystems, bestehend aus den in den Kapiteln 3 bis 5 beschriebenen Algorithmen, zur weiteren Analyse übergeben.

Die schon erwähnte Rauschanregung erfolgte ebenfalls über die Kombination aus Rechnerprogramm und A/D-Wandlerkarte, deren Ausgangssignal lediglich über einen Leistungsverstärker auf den Anregungslautsprecher übertragen wird (Abbildung 6.2.3).

#### 6.2.4.2 Versuchsdurchführung

In den vorstehend skizzierten Versuchsstand werden die vorhandenen Mikrowellenbackröhren nacheinander eingebracht und für circa 30 Sekunden mit weißem Breitbandrauschen angeregt. Der dadurch entstehende Körperschall wird gleichzeitig mittels des piezoelektrischen Beschleunigungssensors auf der Oberseite der Backröhren im Bereich zwischen 100 Hz und 10 kHz erfaßt. Zum Schutz vor Alaisingeffekten erfolgt vor der A/D-Wandlung innerhalb des Ladungsverstärkers eine Tiefpaßfilterung des Beschleunigungssignals mit entsprechender Filtereckfrequenz. Das so vorverarbeitet beschleunigungsproportionale Spannungssignal wird dann durch die Datenerfassungskarte des Rechners mit einer Abtastfrequenz von 20 kHz und einer Amplitudenauflösung von 12bit in ein digitales Signal umgewandelt. Die Meßschriebe mit 512 zeit- und wertdiskreten Amplitudenwerten werden mit einem Hanning-Fenster multipliziert und durch einen FFT-Algorithmus in den Frequenzbereich transformiert. Dort wird ein gemittelttes Summenspektrum aus einhundert Einzelspektren errechnet. Um einen ausreichenden Sicherheitsabstand zur Nyquistfrequenz einzuhalten, werden von den 256 Magnitudenwerten des gemittelten Spektrums nur die ersten 200 Frequenzlinien als Lernmenge mit entsprechender Klassennummer abgespeichert.

Es entsteht eine Lernmenge aus zwei semantischen Klassen. Die „Gut“-Klasse  $W_1$  enthält 45 Stichproben und die Klasse „Einschnürung“ mit der Klassenbezeichnung  $W_2$  beinhaltet einen Stichprobenumfang von insgesamt 44 Spektren. Die Lernmenge wird sodann zur weiteren Verarbeitung an die Merkmalsauswahl übergeben.

### 6.2.5 Klassifikationsergebnisse

Betrachtet man die Spektren in Abbildung 6.2.4 ist man leicht verleitet, die trennenden Merkmalskombinationen im unteren Frequenzbereich zu suchen. Dort sind relativ starke Amplitudenabweichungen zwischen den einzelnen Stichproben der Lernmenge zu erkennen. Der „Wrapper“-Ansatz aus Kapitel 4 wählt jedoch hauptsächlich Merkmalskombinationen aus den höheren „unauffälligeren“ Frequenzbereichen aus. Die auffälligen Amplitudenänderungen und -verschiebungen der unteren, wenig gedämpften Eigenfrequenzen sind somit nicht fehlercharakteristisch sondern hängen stark von den fertigungs- und versuchsbedingten Streuungen ab. Eine Merkmalsauswahl ohne entsprechende Algorithmen durch einfaches „Hinschauen“ ist daher in diesem Fall nicht zielführend und bedarf langer Versuchsreihen.




Abbildung 6.2.4: Amplitudenspektren zweier Stichproben aus der Klasse "Gut" ( $W_1$ ) und der Fehlerklasse "Einschnürung" ( $W_2$ )

Die Suche in der gesamten Suchbasis mit zwei Merkmalen mittels des Abstandsklassifikators (3.25) findet zwar keine Kombination die eine 100%ige Trennung der semantischen Klassen „Gut“ ( $W_1$ ) und „Einschnürung“ ( $W_2$ ) erlauben, allerdings werden immerhin fünf Kombinationen gefunden, die eine Reklassierungsgüte von 0,989 bzw. 98,9 % erreichen (Tabelle 6.2.1). Die beste dieser Kombinationen erreicht eine Zugehörigkeitsdifferenz von 0,485. Eine Reklassierungsgüte von 98,9 % bedeutet, daß eine der 89 Stichproben nicht korrekt klassifiziert wird. Aus Abbildung 6.2.5 geht hervor, daß die Stichprobe mit dem Merkmalsvektor  $m = (22,0; 42,0)$  der semantischen Klasse  $W_2$  mittels der Klassenentscheidung nach Gleichung (3.26) der semantischen Klasse  $W_1$  zugeordnet wird. Dies ist nicht akzeptabel, da damit ein fehlerhaftes Bauteil als



zugeordnet wird. Dies ist nicht akzeptabel, da damit ein fehlerhaftes Bauteil als fehlerfrei klassifiziert wird, und somit ein Strahlungsleck am fertigen Mikrowellenherd auftreten kann. Im nächsten Schritt wird daher die Suchbasis auf den dreidimensionalen Unterraum  $U_0^3$  erweitert, um eventuell Kombinationen aus drei Merkmalen zu finden, die eine Reklassierungsrate von 100% aufweisen.




Abbildung 6.2.5: Merkmalsebene mit Klassifikator der besten Zweiermerkmalskombination

Tabelle 6.2.1: Bestenliste der Merkmalsauswahl im  $U^2$  ohne DHCL<sub>WST</sub>

Nr.	$G_R^2$	$\overline{G}_D$	Fehler	Merkmal 1	Merkmal 2
1	98,876	0,485	1	116	164
2	98,876	0,444	1	115	181
3	98,876	0,415	1	103	115
4	98,876	0,411	1	115	168
5	98,876	0,383	1	115	152
6	97,753	0,520	2	50	138
7	97,753	0,495	2	64	115
8	97,753	0,492	2	115	164
9	97,753	0,492	2	50	115
10	97,753	0,461	2	34	115

Erweitert man die Suche mittels des Algorithmus zur beschränkt optimalen Merkmalsauswahl (Abschnitt 4.2) auf alle möglichen Dreierkombinationen so findet man insgesamt 643 Kombinationen, die eine Reklassierungsrate von 100 % erreichen. Die beste Dreierkombination weist dabei eine Zugehörigkeitsdifferenz von 0,499 auf. Wird

die Suche nach einer geeigneten Dreierkombination dagegen mittels der suboptimalen Methode und einer Bestenlisten  $\hat{U}_0^2$  (Aufnahmebedingung:  $G_R^2 \geq 0,95$ ) durchgeführt, findet man nur noch 102 Kombinationen, die das Kriterium einer 100%igen Trennung erfüllen. Auch hier wird die optimale Dreierkombination aus den Merkmalen 138, 164 und 182 gefunden. Sie steht mit  $G_R^2 = 0,955$  in der Liste der besten Zweierkombinationen an Position 33. Bei einem minimal höheren Grenzwert für die Aufnahme in die Bestenliste würde diese Kombination mit der Methode der suboptimalen Merkmalsauswahl also nicht gefunden werden.

Tabelle 6.2.2: Bestenliste der Merkmalsauswahl im dreidimensionalen Merkmalsraum

Nr.	$G_R^2$	$\bar{G}_D$	Merkmal 1	Merkmal 2	Merkmal 3	2er-Kombination & Listenposition
1	100,0	0,499	138	164	182	138, 164 / 33
2	100,0	0,491	95	164	182	164, 182 / 18
3	100,0	0,489	96	164	182	164, 182 / 18
4	100,0	0,482	50	138	165	50, 138 / 6
5	100,0	0,480	85	164	181	164, 181 / 21

Die schon sehr guten Klassifikationsergebnisse der Suchbasis mit 2 Merkmalen lassen vermuten, daß bei einer Anpassung der Klassenstruktur an die tatsächlich vorliegende Clusterstruktur der Abstandsklassifikators nach (3.25) in der Lage sein sollte, Zweierkombinationen mit einer Reklassierungsrate von 100 % zu finden. Die Grundlage dafür bildet eine Bestenliste  $\hat{U}_0^2$  (Aufnahmebedingung:  $G_R^2 \geq 0,90$ ), für deren 418 Merkmalskombinationen die  $\text{DHCL}_{\text{WST}}$  durchgeführt wird. Als Ergebnis liefert diese Methode sechs Zweierkombinationen die eine 100%ige Trennung erlauben. Die Zugehörigkeitsdifferenz, als Maß für den Interklassenabstand, der besten Kombination liegt mit  $\bar{G}_D \geq 0,540$  sogar 8,2 % über dem Wert der besten Dreierkombination.

Tabelle 6.2.3: Bestenliste der Merkmalsauswahl im  $U^2$  mit  $\text{DHCL}_{\text{WST}}$

Nr.	$G_R^2$	$\bar{G}_D$	Merkmal 1	Merkmal 2	Listenposition ohne $\text{DHCL}_{\text{WST}}$
1	100,0	0,540	115	164	118
2	100,0	0,502	164	164	89
3	100,0	0,491	50	164	22
4	100,0	0,476	50	138	25
5	100,0	0,475	50	164	221
6	100,0	0,429	51	164	119

Aufgrund der Verteilungsdichte der Merkmalsvektoren in der aus den Merkmalen 115 und 163 gebildeten Merkmalsebene, findet die  $DHCL_{WST}$  für die semantische Klasse  $W_1$  keine weiteren Segmente, da die zugehörigen Merkmalsvektoren einen relativ geschlossenen Cluster bilden (Abbildung 6.2.6 a) und c)). Für die semantische Klasse  $W_2$  werden jedoch insgesamt vier Segmente (Staubecken) entsprechend den vier lokalen Maxima des nach (5.8) berechneten Gesamtpotentials gefunden (Abbildung 6.2.6 b) und d)).




Abbildung 6.2.6: Aus den Merkmalen 115 und 163 aufgespannte Merkmalsebene, mit a) den Merkmalsvektoren der semantischen Klasse  $W_1$  über dem Gesamtpotential (grauwertcodiert), b) den Merkmalsvektoren der semantischen Klasse  $W_2$  über dem Gesamtpotential, c) der Klasse  $W_1$  und d) der Klasse  $W_2$  und deren mittels  $DHCL_{WST}$  berechneten vier Segmenten (Staubecken)

Die aus den vier Segmenten mittels (3.25) gebildeten vier elliptischen Subklassen  $W_{21}$  bis  $W_{24}$  passen sich sehr gut der Verteilung der Merkmalsvektoren der semantischen

Klasse  $W_2$  an und führen so zu einer 100%igen Trennung zwischen der Klasse „Gut“ und der Fehlerklasse „Einschnürung“ (Abbildung 6.2.7). Durch die Entstehung der Subklasse  $W_{24}$  aus den am rechten Rand der Merkmalsebene liegenden Merkmalsvektoren werden deren Zugehörigkeiten zur semantischen Klasse  $W_2$  von  $\mu < 0,4$  auf  $\mu > 0,6$  angehoben.




Abbildung 6.2.7: Merkmalsebene mit Klassifikator für die Klassen  $W_1$  und  $W_{21}$  bis  $W_{24}$

Eine vergleichende Bewertung der Lernmenge anhand derselben Merkmale – jedoch diesmal ohne vorherige  $DHCL_{WST}$  – führt zu Fehlklassifikationen mehrerer Merkmalsvektoren. Anhand der eingezeichnete Diskriminante als Grenzfunktion zwischen den beiden semantischen Klassen  $W_1$  und  $W_2$  bei der die gewichteten Schwerpunktsabstände für die Klassen gleich groß sind, ist sofort zu erkennen, daß 6 Merkmalsvektoren der „Gut“-Klasse als fehlerhaft beurteilt werden (Abbildung 6.2.8). Diese Merkmalskombination wäre somit mittels der bisherigen Methode ohne  $DHCL_{WST}$  aufgrund ihrer schlechten Reklassierungsgüte von nur 0,933 nicht zur Klassifikation verwendet worden.




Abbildung 6.2.8: Merkmalsebene (Merkmale 115, 163) mit Klassifikator für die Klassen  $W_1$  und  $W_2$

Die optimalen Klassifikationsergebnisse der Laborexperimente müssen im nächsten Schritt unter den rauen Produktionsbedingungen validiert werden. Zeigen sich dort jedoch ähnlich gute Ergebnisse, dann besteht ein erhebliches Potential, die Produktionskosten durch eine akustische Qualitätskontrolle von Teilkomponenten nach den ersten Fertigungsschritten zu senken.



### 6.3 Akustische Leckagedetektion in Erdgasanlagen

Jedes Erdgas stellt ein Gemisch von mehreren gasförmigen Komponenten dar, deren Anteile je nach Lagerstätte unterschiedlich hoch sein können. Wird von Erdgas als Energieträger gesprochen, so sind dessen Hauptkomponenten Kohlenwasserstoffe, von denen in der Regel das Methan ( $\text{CH}_4$ ) den größten Anteil einnimmt. In geringerem Maße sind auch „höhere“ Kohlenstoffe wie z. B. Äthan und Propan Bestandteile des Erdgases. Darüber hinaus sind fast immer nicht brennbare Bestandteile (Inertgas) wie Kohlendioxid ( $\text{CO}_2$ ) und Stickstoff ( $\text{N}_2$ ) sowie Spuren von Edelgasen vorhanden.

Neben diesen Teilkomponenten haben Erdgase der tieferen geologischen Stockwerke (Zechstein) auch Bestandteile, die sorgfältig ausgewählte Förderausrüstungen, besondere Fördermethoden und ein anschließendes Reinigungsverfahren (Aufbereitung) erfordern. Der in diesem Gas enthaltene Schwefelwasserstoffanteil ( $\text{H}_2\text{S}$ ) – ein übelriechendes, giftiges und stark korrosives Gas – verlangt bei der Förderung besondere Sicherheitsvorkehrungen und setzt den Einsatz von hochqualifiziertem Material voraus.



Abbildung 6.3.1: Bild einer Erdgas-Entschwefelungs-Anlage [Mob83]

Tritt in Erdgasförder- und Aufbereitungsanlagen ein Störfall auf, so besteht nun u. a. die Gefahr, daß Sauer gas in die Atmosphäre austritt. Da Sauer gas jedoch schon in kleinen Dosen tödlich ist, gefährdet es bei Leckagen Mensch und Umwelt in erheblichem Maße. Eine ständige Überwachung der Anlagen ist somit unerläßlich.

### 6.3.1 Aufbereitung von Erdgas

Wie die atmosphärische Luft ist auch Erdgas in der Lage, Feuchtigkeit bis zur Sättigung aufzunehmen. Die Menge des im Gas enthaltenen Wasserdampfes wird durch Druck und Temperatur bestimmt. Da die Erdgas-Lagerstätten generell außer Gas auch Wasser enthalten, ist das geförderte Gas mit Wasserdampf gesättigt, der bei Druckentspannung über Tage und Abkühlung als freies Wasser aus dem Gas auskondensiert.

Dieses Wasser würde in den Fördereinrichtungen und Leitungen hohe Druckabfälle, bei niedrigen Temperaturen Einfrierungen und gegebenenfalls auch Korrosion verursachen. Zur Verhütung dieser unerwünschten Erscheinungen sind vor dem Eintritt des Gases in die Pipeline Einrichtungen erforderlich, mit denen das mitgeführte und kondensierende Wasser abgeschieden wird. In diesen sogenannten Gas-Trocknungs-Anlagen wird darüber hinaus durch Einsatz stark hygroskopischer Chemikalien dem Gas so viel Feuchtigkeit entzogen, daß selbst bei Temperaturen unter dem Gefrierpunkt kein Wasser auskondensieren kann. Dies ist auch bei untertägig verlegten Gasleitungen erforderlich, da in strengen Wintern der Bodenfrost die Leitung erreicht und Einfrierungen in der Leitung verursachen könnte. Hinsichtlich Wirkungsweise, Aufbau und Chemikalieneinsatz gib es verschiedene Methoden für die Gas-Trocknung. Als häufigstes Trockenmittel wird „Glykol“ verwendet, eine organische, hydrophile Flüssigkeit [Mob83].

Der Anteil von Schwefelwasserstoff in deutschem Erdgas kann einen Anteil von 35 Vol.% ausmachen, wodurch dieses Sauer gas ohne besondere Aufbereitungsverfahren für den Energiemarkt wertlos wäre. Der Entzug des Schwefelwasserstoffes aus dem Erdgas erfolgt in besonders dafür konstruierten Erdgas-Entschwefelungs-Anlagen (Abbildung 6.3.1), die sehr hohe Investitionen verlangen, und deren Verfahrenstechnik besondere Fachkenntnisse erforderlich macht.

Die Sauer gas-Aufbereitungs-Anlagen sind eine Kombination aus Gaswäsche- und sog. „Claus-Anlage“. Sie sind eine verfahrenstechnische Einheit, die praktisch in der ganzen Welt ähnlich angewandt wird. Für den Reinigungsprozeß (Wäsche) stehen heute mehrere Verfahren zur Verfügung. In verschiedenen Wäschen kommen unterschiedliche Waschmittel zum Einsatz, die das Kohlendioxid des Rohgases entweder ganz oder teilweise auswaschen. Die verlangte  $H_2S$ -Reinheit wird durch alle Waschmittel erreicht.

Das Rohgas strömt mit einem Druck von ca. 75 bar durch den mit Ventilböden ausgerüsteten Absorber (Abbildung 6.3.2 (1)) im Gegenstrom zum Waschmittel und tritt



als gereinigtes Gas am Absorberkopf aus. Das beladene Waschmittel wird zunächst einem Entspannungsbehälter (Abbildung 6.3.2 (2)) zugeführt. Durch die Druckreduzierung wird vorwiegend das mitabsorbierte Methan mit ca. 50 Vol.%  $\text{H}_2\text{S}$  und  $\text{CO}_2$  freigesetzt. Diese beiden Sauerstoffgasbestandteile werden durch einen Waschmittelteilstrom in einem aufgesetzten Reabsorber (Abbildung 6.3.2 (3)) aus dem Entspannungsgas ausgewaschen. Übrig bleibt ein gereinigtes Gas, das zum Beheizen der Dampfkessel (Erhitzer) benutzt werden kann. Die um den genannten Waschmittelteilstrom vergrößerte Laugenmenge fließt über Lauge/Lauge-Wärmetauscher in die gleichfalls mit Ventilböden ausgerüstete Regenerierkolonne (Abbildung 6.3.2 (7)). Hier erfolgt die Regeneration der Lauge in üblicher Weise mit Dampf, der in einem Erhitzer (Abbildung 6.3.2 (10)) produziert wird. Je nach Beladung und Waschmittelumlauf werden Heizdampfmenngen von 50 bis 90 t/h benötigt. Nach Abkühlung in Lauge/Lauge-Wärmetauschern, Luft- und Wasserkühlern wird das regenerierte Waschmittel mittels einer Hochdruckpumpe in den Absorber zurückgeführt. Das sog. Claus-Gas-hauptsächlich  $\text{H}_2\text{S}$  – wird über den Luftkühler (Abbildung 6.3.2 (8)) und den Abscheider (Abbildung 6.3.2 (9)) zur Claus-Anlage geleitet.




Abbildung 6.3.2: Prinzipskizze einer Erdgas-Entschwefelungs-Anlage [Mob83]

Im Sulfinolabsorber wird das Gas mit Wasserdampf gesättigt. Es muß jedoch mit einem Wassertaupunkt von mindestens  $-5\text{ }^{\circ}\text{C}$  geliefert werden. Deshalb muß das Reingas durch eine Trocknungsanlage geleitet werden.

Die Weiterverarbeitung der in den Wäschen dem Rohgas entzogenen „sauren“ Bestandteile zum Schwefel erfolgt in den Claus-Anlagen. Das Claus-Gas, das bei den verschiedenen Anlagen und Waschverfahren unterschiedlich hohe  $\text{H}_2\text{S}$ -Konzentration (55 bis 85 %) zeigt, wird den Brennkammern, den sog. Clauskesseln, zugeführt. Es wird dann nach bestimmten Reaktionsgleichungen in einem mehrstufigen System zu Elementarschwefel umgewandelt. Der in den Claus-Anlagen anfallende Flüssigschwefel wird in Gruben gesammelt und dort über geheizte Rohrleitungen in Schwefeltanks gepumpt. Der so gespeicherte flüssige Schwefel wird dann u. a. mit Straßentankwagen an die schwefelverarbeitende Industrie ausgeliefert. Die Schwefelproduktion der Claus-Anlagen ist abhängig vom Schwefelwasserstoffgehalt der eingehenden Rohgasmengen. Die Schwefelerzeugung aus Gas mit über 770.000 t allein im Jahr 1999 liegt jedoch rund 10 % über dem Bedarf der deutschen schwefelverarbeitenden Industrie.

### 6.3.2 Überwachung von Erdgasanlagen

Jede Erdgasförderanlage wird bisher regelmäßig alle zwei bis drei Tage von geschultem Überwachungspersonal überprüft. Trotzdem ist ein Störfall während des restlichen unbeobachteten Anlagenbetriebes bei Fernsteuerung nicht ausgeschlossen. Ein Restrisiko durch den Austritt von Sauer gas für Mensch und Umwelt bleibt somit bestehen. Zusätzliche Forderungen nach erhöhter Anlagenverfügbarkeit unter Beibehaltung der Sicherheitsstandards und Einsparung von Betriebskosten müssen zwangsläufig dazu führen, daß die persönliche diskontinuierliche äußere Anlagenüberwachung auf eine kontinuierliche, automatische Überwachung umgestellt wird. Nur eine lückenlose, automatische Überwachung, die über die gewöhnliche Fernwartung hinausgeht und rund um die Uhr die entsprechende Sicherheit bietet, kann auf eventuelle Anlagenstörungen schnell reagieren. Doch dazu müssen die technischen Sensoren stellvertretend für den Menschen kontinuierlich vor Ort verfügbar und entsprechend sensibel sein, um an seiner Stelle unregelmäßige Prozeßabläufe, wie z. B. Leckagen, wahrnehmen und den Anlagenzustand bewerten zu können.

Neben der Kameraüberwachung und der Überwachung durch sogenannte elektronische „Nasen“ kann hier die akustische Geräuschanalyse einen wertvollen Beitrag zur Anlagensicherheit leisten. Im Rahmen des Projektes Human Interface Supervision Systems (HISS) ist dieses modulare Konzept eines Überwachungssystems für Industrieanlagen umgesetzt worden. Innerhalb des Projektes hat der Autor am Institut für Technische Mechanik der TU Clausthal in Zusammenarbeit mit der Firma Sennheiser Luftschall-Messungen an einem Laborversuchsstand zur Leckageortung durchgeführt.

### 6.3.3 Laborversuchsanlage zur Leckagedetektion

Zur Bestimmung des akustischen Verhaltens ausströmender Gase entstand am Institut für Technische Mechanik der TU Clausthal eine kleine Versuchsanlage. Hiermit ist es möglich, bei variablem Druck im Bereich von 0 - 5 bar und unterschiedlichen Volumenströmen von 1 bis 30 m<sup>3</sup>/h die Ausströmgeräusche von Gas durch verschiedene Leckagelochdurchmesser von beispielsweise 0,3 mm, 1,0 mm und 1,5 mm zu erfassen. Der Vorteil dieser Labormessung liegt in der Möglichkeit, die Messungen mit hoher Reproduzierbarkeit der eingestellten Versuchsparameter zu wiederholen. Zusätzlich ist es möglich, dem Ausströmgeräusch verschiedene Hintergrundgeräusche zu überlagern.




Abbildung 6.3.3: a) Ersatzschaltbild der Laborversuchsanlage zur Leckagedetektion an Gasleitungen, b) Diagramm zur Darstellung des Volumenstroms bei unterschiedlichen Öffnungswinkeln des Drosselventils und Anlagendrücken

Für die analoge Datenvorverarbeitung steht ein Präzisions-Schallpegelmesser nach IEC und ANSI Klasse 1 mit integrierter Echtzeit-Terz- & Oktavbandanalyse zur Verfügung. Als Sensor ist ein vorpolarisiertes 1/2 Freifeld-Kondensatormikrofon angeschlossen.

Das rechnergestützte Mustererkennungssystem zur Verarbeitung der Meßdaten ist mit dem der vorherigen beiden Anwendungen völlig identisch und kann ohne Veränderungen an der SubVI-Bibliothek zum Einsatz kommen.

### 6.3.3.1 Versuchsdurchführung und Signalvorverarbeitung

Als Signalvorverarbeitung wird – wie in den vorherigen Anwendungsfällen auch – eine Bestimmung der Frequenzabhängigkeit des abgestrahlten Luftschalls durchgeführt. Neben der Möglichkeit einer schmalbandigen Frequenzanalyse wird bei der Untersuchung von Luftschall jedoch häufig eine breitbandige Analyse des Signals in aufeinander abgestimmten Terzen bzw. Oktaven durchgeführt. Bei der schmalbandigen Analyse ergibt sich die Bandbreite bzw. Frequenzauflösung durch das gewählte Abtastintervall  $\Delta t$  und die Anzahl der erfaßten Meßwerte  $N$ :

$$\Delta f = \frac{1}{N \Delta t} . \quad (6.3.1)$$

Die Gefahr, die sich allerdings bei einer schmalbandigen Analyse des abgestrahlten Luftschalls zur Leckagedetektion ergibt, ist die, daß sich der Klassifikator an rohrspezifischen Merkmalen (z. B. Eigenfrequenzen) orientieren könnte. Um diese Gefahr zu verringern, wird deshalb eine breitbandige Terzanalyse zur globalen Beurteilung der Signale eingesetzt. Bei einer Terzanalyse werden innerhalb aufeinanderfolgender Terzen die schmalbandigen auf das betreffende Band entfallenden Pegel gemäß

$$L_{p_{ges}} = 10 \lg \left( \sum_{i=1}^n 10^{L_{pi}/10} \right) dB \quad (6.3.2)$$

aufaddiert. Die dazu verwendeten akustischen Bandpaßfilter werden durch das Verhältnis

$$\frac{f_o}{f_u} = \sqrt[3]{2} \quad (6.3.3)$$

der oberen zur unteren Grenzfrequenz sowie die Bandmittenfrequenz  $f_{bm}$  charakterisiert. Im vorliegenden Fall werden 19 Frequenzbänder mit den Bandnummern 25 bis 43 erfaßt, woraus sich die Bandmittenfrequenzen

$$f_{bm} = 1000 \cdot 10^{\frac{b-30}{10}} \text{ Hz} , \quad b : \text{Frequenzbandnummer} \quad (6.3.4)$$

ergeben. Die auf diese Weise ermittelten Terzspektren werden zur Verbesserung des Signal-Rausch-Abstandes für 15 Zeitsegmente a 2048 Abtastwerte linear gemittelt.

### 6.3.4 Wissensakquisition mittels DHCL<sub>WST</sub>

Abweichend vom Inhaltlichen Aufbau der Abschnitte 6.1 und 6.2 soll im folgenden der entwickelte Algorithmus zur DHCL<sub>WST</sub> nicht primär zur Optimierung der Klassifikationsgüte des Fuzzy-Prototyp-Klassifikators eingesetzt werden, sondern es soll vielmehr die Frage untersucht werden:

Ist der Algorithmus zur DHCL<sub>WST</sub> prinzipiell in der Lage, aus einer ihm vorliegenden Lernmenge sinnvoll interpretierbares Wissen zu extrahieren?

Um diese Frage zu klären, wird dem Cluster-Algorithmus eine Lernmenge mit Stichproben mehrerer Fehlerklassen, in diesem Fall Terzspektren verschiedener Leckagelochdurchmesser, übergeben. Im Unterschied zu den bisherigen Untersuchungen tragen jedoch alle Merkmalsvektoren der verschiedenen semantischen Fehlerklassen dieselbe numerische Klassenbezeichnung. Eine sinnvolle Clusterung im Sinne der obigen Fragestellung wäre somit die Aufteilung der Klasse „Leckage“ in drei Sub-Klassen, die jeweils die Merkmalsvektoren der entsprechenden Lochgröße in sich vereinen.




Abbildung 6.3.4: Terzspektren für 1,5 und 1,0 mm Leckagelochdurchmesser

Als Testmenge diente eine Datei mit insgesamt 90 Terzspektren, die bei einem Leitungsüberdruck von 4,5 bar und einem Volumenstrom von 30 m<sup>3</sup>/h aufgezeichnet wurden. Die „Leckage“-Klasse  $\mathcal{P}_1$  setzt sich somit aus 3-mal 30 Spektren für die drei Loch-

durchmesser von 0,3 , 1,0 und 1,5 Millimeter zusammen. Die Klassenbezeichnung ist jedoch für alle drei Lochgrößen identisch.

Tabelle 6.3.1: Gütewerte der besten Klassenstrukturen

Nr.	$G_R^2$	$\overline{G}_D$	Merkmal 1	Merkmal 2
1	100,0	0,696	4	7
2	100,0	0,696	1	14
3	100,0	0,695	4	14
4	100,0	0,692	7	14
5	100,0	0,692	14	19

Läßt man sämtliche Clusterstrukturen im zweidimensionalen Merkmalsraum mittels der  $DHCL_{WST}$  segmentieren, ergeben sich für die „Leckage“-Klasse  $\varphi_1$  weit über 100 Merkmalskombinationen mit einer in drei Segmente unterteilten Klassenstruktur. Diese gefundenen Klassenstrukturen sollten nun nach Möglichkeit eine sinnvolle inhaltliche Interpretation bezüglich einer Lochgrößenunterscheidung zulassen. Aus diesem Grund werden die gefundenen Klassenstrukturen mittels der Gütewerte aus Abschnitt 4.1 beurteilt. Zur Berechnung der Gütewerte werden jedoch nicht die aus der Segmentierung ermittelten Klassenbezeichnungen herangezogen, sondern die Merkmalsvektoren werden wieder mit ihren „wahren“ Klassenbezeichnungen versehen. Bei einer Reklassierungsrate von 100 % entspricht die gefundene Clusterstruktur der inhaltlich sinnvollen Klassenstruktur bestehend aus drei semantischen Lochgrößenklassen. Tabelle 6.3.1 zeigt die Gütewerte der besten fünf gefundenen Merkmalskombinationen.




Abbildung 6.3.5: a) mittels  $DHCL_{WST}$  segmentierte Merkmalsebene, b) Merkmalsebene mit Klassifikator

## 7 Zusammenfassung

Das wirtschaftliche Handeln unterliegt wie nahezu jedes zielgerichtete menschliche Handeln dem allgemeinen Vernunftprinzip. Es fordert, ein gesetztes Ziel mit dem Einsatz möglichst geringer Mittel zu erreichen. Die Aufgabe des Ingenieurs ist wiederum eindeutig aus diesem Prinzip abzuleiten. Ihm obliegt es, Maschinen und Anlagen wirtschaftlich zu bauen und zu betreiben. Dies bedeutet neben der Reduzierung des Entwicklungs- und Fertigungsaufwandes auch eine Gewährleistung des Betriebs der maschinellen Anlagen mit einem Maximum an Wirtschaftlichkeit, Qualität und Sicherheit. Dabei hängt die Wirtschaftlichkeit moderner, kapitalintensiver Anlagen und Fertigungseinrichtungen aber nicht nur von ihrer Auslastung sondern insbesondere auch von der Qualität der produzierten Güter und der Verfügbarkeit ab. Überwachungs- und Diagnosesysteme können in diesem Zusammenhang einen wesentlichen Beitrag leisten.

Eine Überwachung und Diagnose von Anlagen und Maschinen muß immer dann erfolgen, wenn Zustände in Folge von Verschleiß oder Ermüdung Änderungen unterworfen sind. Da diese Schädigungsmechanismen dynamische Vorgänge voraussetzen, kommen zur Zustandsbeurteilung vor allem Schwingungs- und Körperschallsignale in Betracht. Durch die moderne rechnergestützte Meßtechnik bietet sich die Verwendung „intelligenter“ computergestützter Diagnosesysteme geradezu an, da die bereits auf dem Rechner digitalisierten Schwingungssignale direkt in Form von zeit- und wertdiskreten Zeitreihen dem Mustererkennungssystem zur Verarbeitung übergeben werden können.

Ein besonderes Problem der Verarbeitung von Schwingungs- und Körperschallsignalen stellen allerdings die erforderlichen hohen Abtastfrequenzen und die für eine ausreichende Frequenzauflösung notwendige Meßfensterlänge dar. Sie zwingen den Anwender zu einer Reduktion des Merkmalsraumes mittels geeigneter Merkmalsauswahlverfahren. In der vorliegenden Arbeit werden zu diesem Zweck die vor allem in den letzten Jahren entwickelten klassifikatorgebundenen Methoden, die sogenannten „Wrapper-Ansätze“, verwendet.

Das zweite wichtige Kernstück eines Mustererkennungssystems ist der verwendete Klassifikator. Die Arbeit erweitert das vor einigen Jahren am Institut für Technische Mechanik der TU Clausthal entwickelte Klassifikationskonzept mittels Zugehörigkeitsfunktionen mit gewichtetem Distanzmaß nach MAHALANOBIS. Diese Zugehörigkeitsfunktionen weisen Einschränkungen bezüglich der zu klassifizierenden Objekte auf, da sich durch sie nur die Struktur für einfach zusammenhängende, konvexe Stichprobencluster in einer mathematisch verhältnismäßig einfachen Form beschreiben und auch nur für diese Struktur befriedigende Klassifikationsergebnisse erzeugen lassen. In Weiterentwick-

lung dieses Klassifikationskonzeptes für einfach zusammenhängende, konvexe Clusterformen wurde ein Algorithmus implementiert, der nicht nur konvexe Clusterformen, sondern insbesondere auch das sogenannte XOR-Problem, welches für viele Klassifikatoren eine schwer lösbare Fragestellung darstellt, verarbeiten kann. Um dies zu erreichen, werden bei Bedarf aus dem durch einen Lehrer vorklassifizierten Lernmengencuster mit Hilfe eines divisiven, hierarchischen Clusterverfahrens, automatisch neue Teilcluster erzeugt. Diese Teilcluster führen dann zu einer optimierten Klassenbildung mittels der Zugehörigkeitsfunktionen mit gewichtetem Distanzmaß. Zum Einsatz kommen dabei Methoden aus der digitalen Bildverarbeitung, die im Rahmen dieser Arbeit erstmals zur Klassifikation von Schwingungssignalen eingesetzt wurden.

Durch diese Erweiterung des Klassifikationskonzeptes wird nun aber nicht nur das Klassifikationsergebnis einer bereits zur Klassifikation ausgewählten Merkmalskombination verbessert, sondern ebenfalls der Algorithmus zur suboptimalen Merkmalsauswahl dahingehend beeinflusst, daß Merkmalskombinationen gefunden werden, die der „Wrapper“-Ansatz sonst verworfen hätte.

Formal läßt sich das in dieser Arbeit vorgestellte Mustererkennungssystem somit in die Funktionsblöcke Signalerfassung, Merkmalserzeugung, Merkmalsauswahl und FUZZY-Klassifikator mit automatischer Clusterung unterteilen. All diese Stufen sind mittels der Softwareentwicklungsumgebung LabVIEW realisiert. Die Grundidee hinter LabVIEW stammt aus dem Bereich der Meßtechnik und verwendet das vertraute Denkmodell der graphischen Blockschaltbilder zur Codegenerierung. Neben der Möglichkeit, Prozesse und Algorithmen durch eine sehr intuitive Form mit Hilfe von Datenflußdiagrammen zu programmieren, bietet LabVIEW leistungsfähige Entwicklungstools für die rechnergesteuerte Datenerfassung und Datenpräsentation. SubVI-Programm-Bibliotheken zur „intelligenten“ automatischen Mustererkennung und Datenanalyse mittels Fuzzy-Methoden standen bisher allerdings nicht zur Verfügung. Diese Lücke zwischen der Datenerfassung und der Datenpräsentation wird nun erstmals durch die im Rahmen dieser Arbeit entstandene SubVI-Toolbox geschlossen. Darauf aufbauend wurden Systeme zur Schwingungsanalyse entwickelt, die diese Toolbox und die darin implementierten unscharfen Methoden erfolgreich auf den Gebieten

- der automatischen Maschinenüberwachung zur Leckageortung an Gasleitungen,
- der akustischen Güteprüfung zur Erkennung von Einschnürungen in Blechformteilen und
- der zahnmedizinischen Diagnostik zur Detektion subgingivaler Konkremente

nutzen.



# Symbolverzeichnis

$A$	unscharfe Meng $A$
$\mathbf{C}_k$	Stichprobenkovarianzmatrix der Klasse $k$
$d_{km}$	beliebiges Distanzmaß zwischen dem Objekt $O_k$ und $O_m$
$d_{km}^e$	euklidischer Abstand zwischen dem Objekt $O_k$ und $O_m$
$\overline{d^e}$	exponentiell gemittelter euklidischer Abstand
$\mathbf{e}_{kn}$	orthonormales Eigenvektorsystem der Klasse $k$
$f$	Frequenz in Hz
$G^M$	Gütemaß auf Basis von $M$ Merkmalen
$\overline{G_D}$	mittlere Zugehörigkeitsdifferenz
$G_R$	Reklassierungsgüte
$K$	semantische Klassenanzahl
$L_j$	Label des Staubeckens $j$
$M$	Dimension eines Unterraumes von $R^N$
$\hat{M}_0$	maximale Dimension des Merkmalsraumes der vollständigen Merkmalsauswahl
$\hat{M}$	maximale Dimension des Merkmalsraumes der suboptimalen Merkmalsauswahl
$\mathbf{m}$	Merkmalsvektor
$N$	maximale Dimension des Merkmalsraumes
$R^N$	Merkmalsraum der Dimension $N$
$\mathbf{r}_k$	Prototyp (Schwerpunktvektor) der Klasse $k$
$S_k$	Stichprobenanzahl der Klasse $k$
$S_R$	Anzahl der korrekt klassifizierten Stichproben (Merkmalsvektoren)
$\mathbf{Q}_k$	Matrix der Eigenvektoren der Stichprobenkovarianzmatrix $\mathbf{C}_k$ der Klasse $k$
$U$	Menge beliebiger Merkmalskombinationen
$U^M$	Menge beliebiger Merkmalskombinationen aus $M$ Merkmalen
$U_j$	bestimmte, mit $j$ numerierte Merkmalskombination

---

$U_0^M$	Menge aller möglichen Merkmalskombinationen mit $M$ Merkmalen
$\tilde{U}$	nach beliebigem Gütemaß sortierte Menge an Merkmalskombinationen
$\hat{U}$	Menge aller Merkmalskombinationen oberhalb eines Grenzwertes eines beliebigen Gütemaßes
$V_{kz}^2$	Anzahl aller möglichen Abstände von $Z_k$ Merkmalsvektoren der Klasse $k$ im zweidimensionalen Merkmalsraume ohne Wiederholung
$x$	beliebiges Element der Menge $X$
$\mathbf{x}$	beliebiger Vektor im Merkmalsraum
$Z_k$	Anzahl zufällig ausgewählter Merkmalsvektoren der Klasse $k$
$\Lambda_k$	Hauptachsentransformierte der Stichprobenkovarianzmatrix $\mathbf{C}_k$ der Klasse $k$
$\mathbf{I}$	Eigenwert der Stichprobenkovarianzmatrix
$\mathbf{m}_A$	skalare Zugehörigkeit zur Menge $A$
$\hat{\mathbf{m}}_s$	maximaler Zugehörigkeitswert (Hauptzugehörigkeit) der Stichprobe $s$
$\boldsymbol{\mu}$	Zugehörigkeitsvektor
$\Phi_k$	Gesamtpotential (Verteilungsdichte) der Klasse $k$
$\Omega_k$	Klassenbezeichnung der Klasse $k$

# Literaturverzeichnis

- [Bac99] BACKHAUS, HORST: „Fuzzy Logic an der Kläranlage Bramsche“. In: *AFN-Berichte 1999*. Clausthal-Zellerfeld : Papierflieger, 1999, S. 62-71.
- [Beh89] BEHR, DIETRICH ; STRACKELJAN, JENS: „Automatische Wälzlagerüberwachung : Schadensklassifikator“. In: *Elektrische Energietechnik*. Heft 5, Heidelberg : Dr. Alfred Hüthig Verlag, 1989, S. 40-43
- [Beh95] BEHR, D. ; STRACKELJAN, J.: “A Feature Selction Method for Acoustic Analysis Problem.” In: *Proc. Third European Congress on Intelligent Techniques and Soft Computing*. Achen, 1995, S. 1175-1180
- [Boo89] BOOSE, JOHAN H.: “A Survey of Knowledge Acquisition Techniques and Tools”. In: *Knowledge Acquisition 1*. 1989, S. 3-37
- [Boo89] BOOSE, J. H.: “A Survey of Knowledge Acquisition Techniques and Tools.”. In: *Knowledge Acquisition 1*, 1989, S. 3-37
- [Bot98] BOTHE, HANS-HEINRICH: *Neuro-Fuzzy-Methoden*. Berlin-Heidelberg : Springer Verlag, 1998
- [Bro98] BRONSTEIN ; SEMENDJAJEW ; MUSIOL ; MÜHLIG: *Taschenbuch der Mathematik auf CD-Rom*. Thun : Verlag Harri Deutsch, 1998
- [Buc83] BUCHANAN, B. ; BARSTOW, D. ; BECHTAL, R. ; BENNETT, J. ; CLANCEY, W. ; KULIKOWSKI, C. ; MITCHELL, T. ; WATERMANN, D. A.: “Constructing an Expert System”. In: HAYES-ROTH, F. ; WATERMANN, D. A. ; LENAT, D. B. (Hrsg.): *Building Expert Systems*, Reading (Maß), 1983, S. 127-167
- [Bun95] BUNK, MICHAEL: *Ein Beitrag zur Anwendung von Methoden der Mustererkennung zur Schadensfrüherkennung an rotierenden Werkzeugen am Beispiel der on-line Rißdiagnose*. Freiberg, Technische Universität Bergakademie, Fakultät für Maschinenbau, Verfahrens- und Energietechnik, Diss., 1995
- [Der87] DERICHE, R.: “Using Canny’s Criteria to Derive a Recursively Implemented Optimal Edge Detector”. In: *Int. Journal of Computing Vision*. Nr. 2, Volume 1, 1986, S. 167-187

- [Der97] DE RAJAT, K. ; PAL NIKHIL, R. ; PAL SANKAR, K. : “Feature Analysis : Neuronal Network and Fuzzy Set Theoretic Approaches”. In: *Pattern Recognition*. 30(10), 1997, S. 1579-1590
- [Dev82] DEVIJVER, PIERE A. ; KITTLER, JOSEF: *Pattern Recognition: a Statistical Approach*. London : Prentice-Hall, 1982
- [Dri96] DRIANKOV, D. ; HELLENDORF, H. ; REINFRANK, M. : *An Introduction to Fuzzy Control*. 2. Aufl., Berlin-Heidelberg : Springer Verlag, 1996
- [Dum88] DUMITRESCU, D. : “Hierarchical Pattern Classification”. In : *Fuzzy Sets and Systems*. Volume 28, 1988, S. 145-162
- [FBI84] FEDERAL BUREAU OF INVESTIGATION (Hrsg.): *The Science of Fingerprints: Classification and Uses*. Washington D. C. : U. S. Government Printing Office, 1984
- [Hän94] HÄNEL, U.: „ERKENNTUNG AN ROTIERENDEN WALZSCHEIBEN MITTELS FUZZY-LOGIK.“ IN: VDI-BERICHT. NR. 113, DÜSSELDORF : VDI-VERLAG, 1994, S. 387-397
- [Har96] HARMS, T. *Multiresolution Bildsegmentierung mit der Wasserscheidentransformation*. Berlin, Technische Universität, Technische Informatik, Diplomarbeit, 1996
- [Hes98] HESSEL, G. ; HOPPE, D. ; SCHMITT, W. ; TEFERA, N. ; VORST, K. VAN DER ; WEIB, F.-P.: *Anwendungsmöglichkeiten neuartiger EDV-gestützter Erkennungsmethoden zur Identifizierung gefährlicher Betriebszustände in Chemieanlagen : Abschlußbericht zum BMBF-Forschungsvorhaben*. Dresden : FZR, Juni 1998
- [Jah02] JAHNS, GERHARD : „Automatische Ruferkennung für landwirtschaftliche Nutztiere“. In: BIETHAN, J. ; KÜHL, J. ; LACKNER, A. (Hrsg.): *Unschärfe in Wirtschaft und Technik*. Göttingen : Arbeitsgemeinschaft Fuzzy Logik und Soft Computing Norddeutschland (AFN), 2002, S. 139-152
- [Jam98] JAMAL, RAMAN ; KRAUSS, PH.: *LabVIEW*. Haar : Prentice Hall, 1998
- [Jol86] JOLLIFFE, I. T.: *Principal Component Analysis*. NEW YORK : SPRINGER, 1986
- [Jon97] JONUSCHEIT, HORST: *Qualitätskontrolle bei Pkw-Getrieben*. Uttenreuth : MEDAV – Digitale Signalverarbeitung GmbH, 1997

- [Jon98] JONUSCHEIT, HORST ; WAGNER, JOACHIM ; GROPE, HOLGER:  
„Vollautomatische Qualitätskontrolle von Dachziegeln“. In: *Ziegelindustrie International*. Heft 11, Walluf : Bauverlag, 1998, S. 741-751.
- [Kle98] KLEIN, ULRICH: *Schwingungsdiagnostische Beurteilung von Maschinen und Anlagen*. Düsseldorf : Stahleisen, 1998
- [Koc97] KOCHER, TH. ; RÜHLING, A. ; MOMSEN, H. ; PLAGMANN, H. C. : *Effectiveness of subgingival instrumentation with power-driven instruments in the hands of experienced and inexperienced operators*. TA study on manikins. J Clin Periodont 24, 1997, S. 498-504
- [Kol92] KOLB, H.-J.: „Werkzeuge für das Objektivieren und Automatisieren der akustischen Qualitätsprüfung“. In: *Qualität und Zuverlässigkeit*. 1992, Heft 3, S. 161-164.
- [Kra00] KRAMER, KLAUS-D. ; BRAUNE, STEFFEN ; WÖHLBIER, SVEN: „Fuzzy-Control-Algorithmen für Low-Cost-Microcontroller“ In: *AFN-Berichte 2000*. Clausthal-Zellerfeld : Papierflieger, 2000, S. 38-47
- [Kuh00] KUHN, CHRISTIAN: “Überwachung des Destillationsprozesses für Laboranwendungen mittels Fuzzy-Ablaufsteuerung“ In: *AFN-Berichte 2000*. Clausthal-Zellerfeld : Papierflieger, 2000, S. 48-57
- [Le01] LE, TU V. ; CHEUNG, KA Y. ; NGUYEN, MINH H.: “A Fingerprint Recognizer Using Fuzzy Evolutionary Programming”. In: *Proc. Of the 34<sup>th</sup> Hawaii International Conference on System Sciences*. Maui, 2001
- [Leh97] LEHMANN, T. ; OBERSCHERP, W. ; PELIKAN E. ; REPGES, R.: *Bildverarbeitung für die Medizin*, Berlin : Springer, 1997
- [Liu92] LIU, K. ; CHENG, Y.-Q. ; YANG, J.-Y.: “A Generalized Optimal Set of Discriminant Vectors”. In: *Pattern Recognition*. 25-7, 1992, S. 731-739
- [Lut02] LUTZ, HOLGER ; WENDT, WOLFGANG: *Taschenbuch der Regelungstechnik*. 4., korr. Aufl., Frankfurt a. M. : Verlag Harri Deutsch, 2002
- [Mah36] MAHALANOBIS, P. C.: *On the generalized distance in statistics*. Poc. Indian Nat. Inst. Sci. Calcutta, 1936, S. 49-55
- [Mob83] MOBIL OIL AG: *Erdöl, Erdgas : Suchen, Förder, Verarbeiten*. 11. Aufl., Hamburg, 1983
- [Nie83] NIEMANN, H.: *Klassifikation von Mustern*. Berlin : Springer-Verlag, 1983

- [Oes98] OESTERWIND, ROLAND: *Ein Verfahren zur Identifikation von Rissen mittels aktiver Schwingerregung und unscharfer Mustererkennungsverfahren*. Clausthal, Technische Universität, Fakultät für Bergbau, Hüttenwesen und Maschinenwesen, Diss., 1998
- [Ott98] OTTE, CLEMENS: *Fuzzy-Prototyp-Klassifikatoren und deren Anwendung zur automatischen Merkmalsselektion*. Oldenburg, Carl-von-Ossietzky-Universität, Fachbereich für Informatik, Diss., 1998
- [Pal97] PALM, R. ; DRIANKOV, D. ; HELLENDORF, H. : *Model Based Fuzzy Control*. Berlin-Heidelberg : Springer Verlag, 1997
- [Par62] PARZEN, E.: "On estimation of a probability density function and mode". In: *Ann. Math. Stat.* Nr. 33, 1962, S. 1065-1076
- [Pet91] PETERS, H.: „Einsatz von Mustererkennungsverfahren zur Anlagenüberwachung“. In: *Stahl und Eisen*. 111, 1991, S. 88 – 92
- [Rau93] RAUBER, T. W. ; BARATA, M. M. ; STEIGER-GARCAO, A. S.: "A Toolbox for Analysis and Visualisation of Sensor Data in Supervision." In: *Tooldiag '93 – International Conference on Fault Diagnosis*. Toulouse, 1993
- [Rau97] RAU, REINALD : „Fuzzy-Logik zur Aufklärung von Kreditkartenbetrug“. In: BIETHAN, J. ; KUHLE, J. ; LEISEWITZ, M.-C. ; NISSEN, V. ; TIETZE, M. (Hrsg.): *Softcomputing-Anwendungen im Dienstleistungsbereich*. Göttingen : Arbeitsgemeinschaft Fuzzy Logik und Soft Computing Norddeutschland (AFN), 1997, S. 79-99
- [Sch01] SCHUBERT, ANDREAS: *Der Einsatz von intelligenten Methoden zur Diagnose von Maschinen- und Prozeßzuständen und ihre Integration in die Instandhaltungsstrategie chemischer Anlagen*. Clausthal, Technische Universität, Fakultät für Bergbau, Hüttenwesen und Maschinenwesen, Diss., 2001
- [She92] SHEN, J. ; CASTAN, S.: "An Optimal Linear Operator for Step Edge Detection". In: *Computer Vision, Graphics and Image Processing*. Nr. 54, 1992, S. 112-133
- [Soi98] SOILLE, PIERRE: *Morphologische Bildverarbeitung: Grundlagen, Methoden, Anwendungen*. Berlin : Springer, 1998
- [Spä75] SPÄTH, H.: *Cluster-Analyse Algorithmen*. München, 1975

- [Sto00] STOLPMANN, ALEXANDER ; ANGELE, JÜRGEN: „Soft-Computing System zur Fehlererkennung in Furnierholz“. In: *AFN-Berichte 2000*. Clausthal-Zellerfeld : Papierflieger, 2000, S. 99-107.
- [Stö95] STÖCKER, HORST (Hrsg.): *Taschenbuch mathematische Formeln und moderne Verfahren*. 3., überarb. und erw. Aufl., Frankfurt a. M. : Verlag Harri Deutsch, 1995
- [Str02] STRACKELJAN, JENS: *Einsatzmöglichkeiten von Softcomputing-Methoden zur Auslegung, Optimierung und Überwachung von Rotorsystemen*. Clausthal, Technische Universität, Fakultät für Bergbau, Hüttenwesen und Maschinenwesen, Habilitationsschrift., 2003
- [Str03] STRACKELJAN, JENS ; DOBRAS, JENS ; MITZSCHKE, DETLEF: „Dem Zahnstein auf der Spur“. In: *TU Contact*. Nr. 13, 7. Jahrgang, Clausthal : 2003 , S. 54-58
- [Str93] STRACKELJAN, JENS: *Klassifikation von Schwingungssignalen mit Methoden der unscharfen Mustererkennung*. Clausthal, Technische Universität, Fakultät für Bergbau, Hüttenwesen und Maschinenwesen, Diss., 1993
- [Tra91] TRAUWAERT, E. ; KAUFMANN, L. ; ROUSSEEUW, P.: “Fuzzy Clustering Algorithms Based on the Maximum Likelihood Principle”. In : *Fuzzy Sets and Systems*. Volume 42, 1991, S. 213-227
- [Tra99] TRAN, D. ; LE, T. V. ; WAGNER, M.: “Fuzzy Evolutionary Programming for Hidden Markov Modelling in Speaker Identifikation”. In: *Proc. Of the Congress of Evolutionary Computation 99*. Washington D.C., Juli 1999, S. 812-815
- [Wah84] WAHL, F. M.: *Digitale Bildsignalverarbeitung : Grundlagen, Verfahren, Beispiele*. BERLIN : SPRINGER, 1989
- [Web92] WEBER, RICHARD: *Entwicklung und Anwendung von Verfahren zur automatischen Akquisition unsicherer Wissens*. Düsseldorf : VDI-Verlag, 1992
- [Weg98] WEGNER, S. ; SAHLSTRÖM, A. ; PLEIBNER, K.-P. ; OSWALD, H. ; FLECK, E.: „Eine hierarchische Wasserscheidentransformation für die Spotdetektion in 2D Gelektrophorese-Bildern“. In: *Bildverarbeitung in der Medizin: Algorithmen-Systeme-Anwendungen*. BERLIN : SPRINGER, MÄRZ 1998, S. 134-138
- [Win81] WINDHAM, M. P.: “Cluster Validity for Fuzzy Clustering Algorithm”. In : *Fuzzy Sets and Systems*. Volume 5, 1981, S. 177-185

- [Wöh81] WÖHE, GÜNTER: *Einführung in die Allgemeine Betriebswirtschaftslehre*. 14., überarb. Aufl., München : Verlag Franz Vahlen, 1981
- [Xu94] XU, YONGLONG: „Untersuchung der Bildsegmentierung zwecks der nachfolgenden wissensbasierten Bildanalyse“. IN: *Spatial Information from Digital Photogrammetry and Computer Vision, International Archives of Photogrammetry and Remote Sensing*. VOLUME 30, 1994, , PART 3/1, S. 931-938
- [Zad65] ZADEH, LOFTI A.: „Fuzzy Set“. In: *Information and Control*. 1965, Nr. 8, S. 338-353
- [Zah04] *Behandlung von Zahnbetterkrankungen* [online]. Copyright: zahn-forum, Kassenärztliche Vereinigungen Baden-Württembergs, 2004, erhältlich unter [www.zahn-forum.de/zf/zf.nsf/ContentByKey/RZIN-578QDR-DE-p](http://www.zahn-forum.de/zf/zf.nsf/ContentByKey/RZIN-578QDR-DE-p)
- [Zim91] ZIMMERMANN, HANS-JÜRGEN: *Fuzzy Set Theory and its Applications*. 2. Aufl., Boston, 1991
- [Zim93] ZIMMERMANN, HANS-JÜRGEN (Hrsg.): *Fuzzy-Technologien : Prinzipien, Werkzeuge, Potentiale*. Düsseldorf : VDI-Verlag, 1993
- [Zim95] ZIMMERMANN, HANS-JÜRGEN (Hrsg.): *Datenanalyse : Anwendung von DataEngine mit Fuzzy Technologien und Neuronalen Netzen*. Düsseldorf : VDI-Verlag, 1995



## Lebenslauf

Persönliches:	Jens Dobras.
08.09.1971	Geboren in Delmenhorst als Sohn des Postbeamten Alfred Dobras und seiner Ehefrau Marga Dobras, geb. Grote.
Schulische und berufliche Ausbildung:	
1978 – 1982	Besuch der Grundschule an der Beethovenstraße in Delmenhorst.
1982 – 1984	Besuch der Orientierungsstufe West in Delmenhorst.
1984 – 1988	Besuch des Gymnasiums an der Max-Planck-Straße in Delmenhorst.
1988 – 1992	Besuch des Fachgymnasiums für Technik an der Kerschensteiner-Schule in Delmenhorst.
19.05.1992	Abschluß mit der Allgemeinen Hochschulreife
1992 – 1993	Grundwehrdienst bei der Luftwaffe in Hamburg und Delmenhorst
1993 – 1998	Studium des Maschinenbaus an der Technischen Universität Clausthal mit der Studienrichtung Allgemeiner Maschinenbau
23.09.1998	Abschluß der Diplomhauptprüfung an der Technischen Universität Clausthal.
seit 01.10.1998	Wissenschaftlicher Mitarbeiter am Institut für Technische Mechanik der Technischen Universität Clausthal.